

Trabajo Fin de Grado

Evaluación y comparación de técnicas temporales y
frecuenciales aplicadas a la detección de fatiga
muscular a partir de señales sEMG

Autor

José María Lizano Lacasa

Director

Diana Ruiz Bueno

Ponente

Luis Montano Gella

Escuela de Ingeniería y Arquitectura
2014

Evaluación y comparación de técnicas temporales y frecuenciales aplicadas a la detección de fatiga muscular a partir de señales sEMG

Resumen

En este trabajo se han estudiado diferentes indicadores de fatiga muscular, obtenidos a partir de la señal eléctrica producida por los músculos al contraerse (EMG), para su uso en el desarrollo de un algoritmo de detección de fatiga muscular que aprenda, mediante técnicas de aprendizaje no supervisado, a detectar cuando un paciente está fatigado, de forma que se pueda integrar en un modelo de estimación de fuerzas musculares, basado en el modelo de Hill, para permitir que se ajuste correctamente a situaciones de fatiga. También se han estudiado las sinergias musculares, una teoría cada vez más probada y aceptada, que establece que el sistema nervioso dispone de una librería de sub-tareas motoras (las sinergias) que puede combinar de forma flexible para generar cualquier movimiento, estas sinergias se obtienen a partir de la señal EMG mediante técnicas de reducción de dimensión.

Contenido

Capítulo 1 Introducción.....	0
Capítulo 2 Electromiografía.....	3
2.1 Fundamentos y procesamiento de la señal electromiográfica	3
2.2 Sinergias musculares.....	8
Capítulo 3 Fatiga	14
Capítulo 4 Algoritmo de detección de fatiga	21
Capítulo 5 Integración en un modelo de músculo	27
Capítulo 6 Experimentación.....	34
6.1 Sujetos.....	34
6.2 Equipo y adquisición de datos	35
6.2.1 Kinect	36
6.3 Protocolo experimental	37
Capítulo 7 Resultados	41
7.1 Indicadores de fatiga.....	41
7.2 Sinergias.....	49
7.3 Algoritmo de detección de fatiga.....	53
7.4 Modelo de músculo.....	58
Capítulo 8 Conclusiones	63
Capítulo 9 Bibliografía.....	66
Anexo I Músculos medidos	69
Anexo II Opensim	73
Anexo III Resultados adicionales.....	75

Anexo IV Cronograma y desarrollo de algoritmos	93
Anexo V Funcionamiento Kinect	97
Anexo VI Transformada Wavelet.....	102
Glosario	105

Capítulo1

Introducción

Este trabajo se enmarca dentro del proyecto HYPER [30], donde se pretende desarrollar un dispositivo híbrido neuroprotésico y neurorrobótico cuyo objetivo es la restauración de la función motora en pacientes con lesión medular a través de la compensación funcional y promover el re-aprendizaje del control motor en pacientes afectados por accidente cerebro vasculares y parálisis cerebral, por medio de un uso integrado de estos dispositivos.

El paradigma de control en HYPER se basa en las señales electromiográficas (EMG), señales eléctricas que los músculos producen al activarse y que pueden ser medidas con electrodos superficiales. Estas señales serán usadas en el control del exoesqueleto (Figura 0), pues sirven para estimar la fuerza muscular ejercida por el paciente y la compensación necesaria para la realización del ejercicio.

Un fenómeno que aparece durante los ejercicios de rehabilitación, debido a que las tareas son repetitivas y a las condiciones de los pacientes, es la fatiga. Pocos estudios han tratado de tener en cuenta la presencia de fatiga al investigar las fuerzas musculares o su contribución al momento neto. Esta fatiga se puede detectar a partir del EMG o con galgas extensiométricas que incorporan algunos exoesqueletos. En este proyecto se va a trabajar sobre el EMG ya que el exoesqueleto al que se aplicará en un futuro no dispone de galgas. Se estudiarán algunas de las métricas propuestas para detección de fatiga en diferentes trabajos de investigación, para comprobar su validez y eficacia.

Adicionalmente también se estudiará la validez como indicador de fatiga de una nueva teoría surgida en los últimos años, y cada vez más aceptada, las sinergias musculares. Esta teoría postula que el sistema neural no controla cada músculo de forma individual y única para cada movimiento que se quiera realizar, sino que dispone de una librería de sub-tareas motoras (las

sinergias) que combina de distintas formas para crear cada movimiento. Estas sinergias son obtenibles directamente a partir del EMG con diferentes técnicas de reducción de dimensión. De confirmarse esta teoría supondría un gran avance en el entendimiento del sistema neuromotor, pues tendríamos un mecanismo de representación de información sobre las estrategias subyacentes de control neural que intervienen en el movimiento.

Una vez estudiados estos parámetros se desarrollará un algoritmo de detección de fatiga para las terapias de rehabilitación basado en aquellos índices que hayan dado mejores resultados. Se ha optado por la técnica de aprendizaje no supervisado, ya que a priori no se conoce el estado del sujeto (fatigado o no), y el exoesqueleto debe ser capaz de adaptarse dinámicamente a dicho estado.

Es importante entonces la detección de la fatiga durante las terapias de rehabilitación para modificar la estrategia de control sobre el exoesqueleto. La estimación de la fuerza generada por el paciente a partir del EMG se realiza a través de un modelo muscular llamado Modelo de Hill. Este modelo utiliza el EMG y la cinemática del movimiento para estimar la contribución al movimiento de cada músculo. Varios estudios han mostrado que en presencia de fatiga este modelo deja de ajustarse al comportamiento del músculo debido a que los cambios que se producen en el EMG hacen que varíe la relación EMG-Fuerza muscular, es por ello que se necesita algún tipo de ajuste para corregir esto.




Figura 0. Ejemplos de exoesqueletos de miembro superior.

En este trabajo compararemos las sinergias obtenidas en un ejercicio de fatiga y las obtenidas en uno de no fatiga. En el caso de mantenerse relativamente constantes reforzaría el hecho de que representan información sobre las estrategias subyacentes de control neural y no sólo actividad muscular.

Todos los estudios realizados en este trabajo se han valido con datos de sujetos reales sanos, de los que se han grabado tanto el EMG como la información cinemática de los movimientos. Para obtener esta información cinemática se ha trabajado en adaptar un sistema de tracking del movimiento (Kinect) para poder capturar de forma sincronizada el EMG y posición de las articulaciones de codo y hombro.

En primer lugar se hará una introducción a la electromiografía y la naturaleza fisiológica de la señal, en el capítulo 3 y 4 se presentarán los indicadores de fatiga estudiados y el algoritmo de detección de fatiga finalmente desarrollado. En el capítulo 5 se muestra la integración realizada de este detector en un modelo de músculo, de forma que se ajuste correctamente el comportamiento del músculo incluso en presencia de fatiga. En el capítulo 6 se explican los experimentos realizados, así como los sujetos participantes y los protocolos seguidos. Por último los capítulos 7 y 8 muestran los resultados obtenidos en los diferentes apartados y las conclusiones que estos resultados han suscitado. En cuanto a los anexos, el Anexo I muestra los músculos medidos en los experimentos, el Anexo II hace una breve presentación de la herramienta OpenSim utilizada en este proyecto, el Anexo III contiene resultados similares a los mostrados en el capítulo 7 pero para otros músculos, el Anexo IV contiene la distribución del trabajo en la duración del proyecto y un breve análisis del código generado, el Anexo V explica el funcionamiento de la cámara Kinect y el Anexo VI explica la transformada Wavelet, utilizada en el análisis frecuencial de la señal EMG.

Capítulo 2

Electromiografía

2.1 Fundamentos y procesamiento de la señal electromiográfica

El proceso de activación de un músculo se puede resumir de la siguiente manera, el cerebro manda la orden de activación al músculo, a través de las **unidades motoras**, que son la unidad funcional más pequeña en el proceso del control neural de la contracción muscular. Una unidad motora se define como *"El cuerpo celular y las dendritas de una neurona motora, las múltiples ramificaciones de su axón y las fibras musculares que excita"*. El termino unidades refleja que todas las fibras musculares de una unidad motora actúan como una en el proceso de excitación. Estas unidades motoras se encargan de excitar las fibras musculares para conseguir la contracción del músculo.

La Electromiografía (EMG) es una técnica para la evaluación y registro de la actividad eléctrica producida por los músculos en este proceso de activación (figura 1). Hay dos métodos para obtener el EMG, uno es el **superficial**, y el otro método es el **intramuscular**. Para llevar a cabo un EMG intramuscular se usa una aguja electrodo, que se inserta a través de la piel hasta que entre al tejido muscular, lo que puede ser considerado demasiado invasivo. En su lugar, el método superficial emplea una superficie en la cual el electrodo se puede utilizar para controlar la imagen general de la activación muscular, a diferencia de la actividad de sólo unas pocas fibras como se observa utilizando un EMG intramuscular. Para la realización de todos los experimentos de este proyecto se ha utilizado la técnica de EMG superficial.

El EMG es aplicado en una amplia variedad de campos, desde la rehabilitación a las ciencias del deporte, su utilidad radica en que es uno de los pocos métodos que proporciona visión directa sobre la actividad muscular, y por lo tanto sobre la producción de fuerza muscular durante movimientos funcionales. La **Dinámica inversa** (ver Anexo II) por ejemplo, nos permite calcular el momento neto producido por todos los músculos que actúan sobre una articulación, pero presenta un problema de distribución debido a que este momento debe ser distribuido en varios músculos, habiendo más incógnitas que ecuaciones. De hecho la fuerza muscular sólo puede ser medida mediante procedimientos invasivos y sólo en algunos músculos.

Este conocimiento sobre la magnitud individual de cada fuerza muscular es importante en investigación biomecánica, para entender el control motor por ejemplo, debido a que las fuerzas musculares son el principal determinante en la carga articular (par o momento neto). Ya que el EMG nos proporciona información sobre las actividades musculares individuales nos puede ayudar a resolver este problema, de hecho las estimaciones de fuerza muscular están frecuentemente basadas en medidas de EMG superficial.




Figura 1. Ejemplo de señal EMG sin procesar. Muestra del aspecto de una señal EMG, la longitud de los tiempos de descanso dependen de la velocidad a la que se realiza el ejercicio.

El EMG es una señal eléctrica, medida en micro voltios, y con la mayor parte de la energía de la señal por debajo de los 500Hz, normalmente concentrada en la banda entre los 50 y 150Hz. Su aspecto es el de la figura 1, donde cada *Active Contraction Burst* representa trabajo o actividad muscular (contracción del bíceps por ejemplo) y el *rest*

period representa el tiempo que el músculo permanece en reposo entre dos de estas contracciones.

Normalmente no se trabaja con el EMG sin procesar, es mucho más útil contar con una medida de activación muscular que nos indique el grado de activación relativo del músculo. Para obtener dicho nivel de activación muscular a partir de la señal EMG sin procesar se siguen los siguientes pasos:

1. Filtro Paso alto a 30Hz : Para eliminar posibles componentes ruidosas de la señal EMG. El resultado se muestra en la figura 2.




Figura 2. Nivel de activación obtenido a partir del EMG.

2. Rectificación de la señal: Se convierten todas las amplitudes negativas a amplitudes positivas. En la figura 3 se puede ver el resultado.




Figura 3. Nivel de activación obtenido a partir del EMG.

3. Filtro Paso Bajo a 5Hz : Para obtener la envolvente de la señal. La figura 4 muestra el resultado.




Figura 4. Nivel de activación obtenido a partir del EMG.

4. Normalización: Se normaliza respecto de la amplitud máxima (normalmente obtenida de la máxima contracción voluntaria, ver capítulo 6). Con esto se obtiene una medida de activación normalizada entre 0 y 1, como muestra la figura 5.




Figura 5. Nivel de activación obtenido a partir del EMG.

Todos los filtros mencionados son Butterworth de cuarto orden, para minimizar el retraso en la respuesta. No todos los músculos se activan por igual durante ejercicio, aquellos músculos que realizan más trabajo tienen activaciones más altas como se puede

ver en la figura 6. Es por ello que a la hora de analizar los resultados, se analiza el músculo que más influencia tiene en el ejercicio (ver capítulo 7).




Figura 6. Comparación de activaciones para ejercicio de Deltoides. De arriba a abajo, activación de Deltoides(anterior, medio y posterior), Bíceps, Tríceps (Long, lateral y medial) y brachioradialis. Como se puede ver las mayores activaciones pertenecen a los deltoides, que son los músculos que más intervienen en este ejercicio

2.2 Sinergias musculares

Tradicionalmente, el término "sinergia" ha sido usado clínicamente para describir la co-activación patológica de los músculos como la vista tras los accidentes cerebro vasculares, que llevan a una disfunción en la coordinación entre articulaciones. Sin embargo en los últimos años, el concepto de sinergia muscular ha regresado al campo de la neurociencia como una propuesta de **mecanismo de control neural en el movimiento normal** [1].

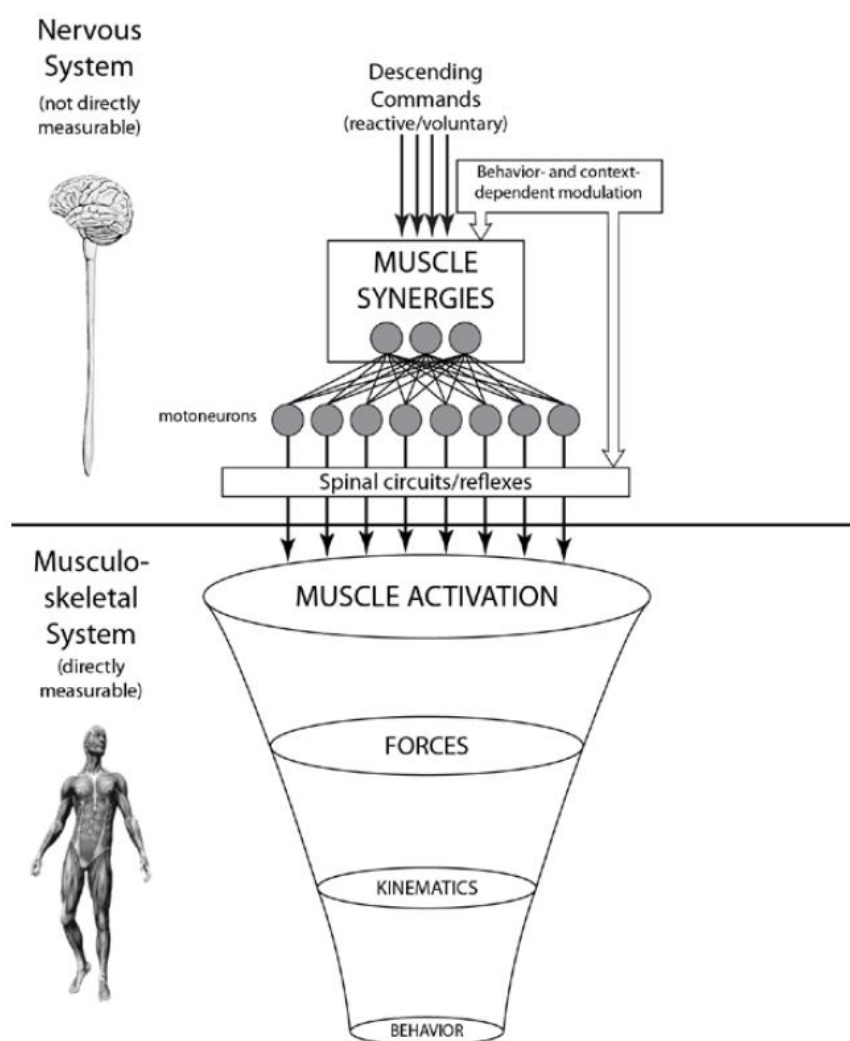


Figura 7. Modelo conceptual de la coordinación motora. El sistema neuro motor combina la sinergias para formar alguno de los posibles patrones de activación, estos generan un conjunto más pequeño de posibles fuerzas, las que a su vez producen un conjunto más pequeño de cinemáticas y estas por último a un conjunto aun más pequeño de comportamientos motores.

Concretamente se ha sugerido que las sinergias musculares en sujetos sanos representan patrones funcionales de coordinación muscular usados para producir funciones motoras de forma fiable durante comportamientos motores naturales. Esto sugiere que la existencia de sinergias musculares en la producción de movimientos no tienen porque estar limitadas a la patología, si no que pueden reflejar un principio general de control neural.

La hipótesis adoptada en este trabajo respecto a las sinergias musculares es la seguida (y cada vez más aceptada) por la tendencia actual de la investigación biomecánica: **Las sinergias representan una librería de sub-tareas motoras que el sistema nervioso puede combinar de forma flexible para producir movimientos naturales complejos** [1], como representa la figura 7.

En nuestra formulación de las sinergias cada una define un ratio consistente de co-activación muscular necesaria para coordinar segmentos del cuerpo para llevar a cabo una sub-tarea motora. Una sinergia puede estar formada de cualquier número de músculos, y un músculo puede pertenecer a múltiples sinergias.

La utilidad de las sinergias radica en que representan información sobre las estrategias subyacentes de control neural que intervienen en el movimiento. Como se ha dicho, es posible medir la activación muscular durante movimientos a través del EMG, sin embargo es difícil interpretar sus implicaciones funcionales durante tareas motoras, debido a la variabilidad inherente a las señales EMG, particularmente cuando se trabaja con gran variedad de pacientes. El mismo movimiento puede ser ejecutado por un amplio espectro de patrones musculares, debido a la abundante musculatura del cuerpo humano.

Sin embargo las sinergias reflejan un principio general de control neural, lo que nos proporciona un análisis más robusto, menos sujeto a la variedad en la población. Un aspecto a destacar es que se ha demostrado que se pueden usar las sinergias en el marco del diagnóstico clínico. Por ejemplo se podría predecir el grado de discapacidad de pacientes que han sufrido un ataque cerebro-vascular en función de la reducción del número de sinergias [2].

Uno de los objetivos de este trabajo es comprobar si las sinergias se mantienen estables a través de diferentes condiciones de fatiga o no, y por tanto si se podrían usar como herramienta para la detección de la misma.

Extracción de sinergias musculares

Existen dos modelos principales de sinergias, sinergias variantes en el tiempo y sinergias no variantes en el tiempo. El primer modelo representa las sinergias como activaciones coordinadas de grupos de músculos con perfiles específicos variantes en el tiempo, mientras que el segundo mantiene que las sinergias permanecen estables y lo que varía son los pesos que el sistema neural otorga a cada sinergia para realizar la combinación.

En este trabajo se utilizan sinergias no variantes en el tiempo, concretamente el modelo de sinergias generalizado para la coordinación muscular *feed-forward* [3] propuesto en la literatura actual (figura 8). Una sola sinergia representa las activaciones correladas y determinadas espacialmente de un grupo de músculos.

Cada vector sinergia de correlaciones musculares $\{\vec{w}_i \mid i = 1, \dots, n\}$ es activado por la correspondiente señal neural $\mathbf{h}_i(t)$ variante en el tiempo. La activación total de un músculo j es la suma de sus representaciones en cada sinergia (w_{ij}) ponderada por la correspondiente entrada neural ($\mathbf{h}_i(t)$), es decir:

$$v_j(t) = \sum_{i=1}^n w_{ij} \cdot h_i(t) \quad \{v, w, h\} \geq 0$$

$$\forall \{i = 1, \dots, n, j = 1, \dots, m\} \quad (1)$$

El modelo completo se puede escribir en forma matricial como:

$$V_{mxo} = W_{mxn} \mathbf{x} H_{nxo}$$

$$V_{mxo} = \begin{bmatrix} \vec{v}_1(t) \\ \vec{v}_2(t) \\ \vdots \\ \vec{v}_m(t) \end{bmatrix}$$

$$W_{m \times n} = \begin{bmatrix} w_{11} & w_{21} & \dots & w_{n1} \\ w_{12} & w_{22} & \dots & w_{n2} \\ \dots & \dots & \dots & \dots \\ w_{1m} & \dots & \dots & w_{nm} \end{bmatrix}$$

$$H_{n \times o} = \begin{bmatrix} \vec{h}_1(t) \\ \vec{h}_2(t) \\ \vdots \\ \vec{h}_m(t) \end{bmatrix} \quad (2)$$

donde V es la matriz $m \times o$ (m músculos, o muestras) de los datos EMG obtenidos, W es la matriz $m \times n$ (n sinergias, $m > n$) de sinergias (cada sinergia una columna) y H es la matriz $n \times o$ de entradas neurales variantes en el tiempo. Intuitivamente, $\vec{h}_j(t)$ representa el grado de uso que el sistema neural hace de la sinergia w_j en el instante t , es decir el factor por el que escala la sinergia j para combinándola con las otras sinergias obtener el movimiento a realizar en el instante t , V la conocemos, pues es el EMG medido, y W y H tienen que ser calculadas. La ecuación (1) es la versión tiempo-dependiente del modelo de sinergias, en este trabajo, sin embargo, se ha usado en la forma de la ecuación (3). Se calcula la media de los patrones EMG de o muestras discretas en vez del patrón temporal de una única muestra.

$$v_j[r] = \sum_{i=1}^n w_{ij} \cdot h_i[r] \quad \{v, w, h\} \geq 0$$

$$\forall \{i = 1, \dots, n, j = 1, \dots, m, r = 1, \dots, o\} \quad (3)$$

Existen varios algoritmos para determinar W y H , incluyendo análisis de componentes principales (*principal components analysis*, PCA) y análisis de componentes independientes (*independent component analysis*, ICA). En este trabajo se ha elegido el método de factorización de matrices no negativas (*non negative matrix factorization*, NMF) ya que se ha publicado que funciona mejor que PCA, y al menos igual de bien que ICA, en el cálculo de sinergias subyacentes a un conjunto de datos en presencia de ruido [4]. Esto nos es muy conveniente debido al ruido inherente a la señal EMG. Además NMF no restringe a las sinergias obtenidas a ser ortogonales o estadísticamente independientes, como si hacen PCA e ICA respectivamente[5,6]. Finalmente, dado que

las activaciones musculares son voltajes positivos, las sinergias obtenidas por NMF probablemente tendrán más relevancia fisiológica debido a la restricción de la no negatividad [7]. Debido a esta restricción se trabaja con el nivel de activación obtenido a partir del EMG, en vez de con el EMG crudo (ver capítulo 2).

De forma abreviada el proceso es el siguiente: se inicializan con valores aleatorios las matrices estimadas W_{est} y H_{est} y son iterativamente actualizadas siguiendo las siguientes reglas:

$$\begin{aligned}
 W_{n+1} &= W_n * \frac{V \times H_n^T}{W_n \times H_n \times H_n^T} \\
 H_{n+1} &= H_n * \frac{W_n^T \times V}{W_n^T \times W_n \times H_n} \\
 W_{n+1}(c) &= \frac{W_{n+1}(c)}{\text{norm}(W_{n+1}(c))} \quad \forall \text{ columna } 'c', \tag{4}
 \end{aligned}$$

donde '*' es la multiplicación elemento a elemento, '/' es la división matricial elemento a elemento y 'x' es la multiplicación matricial estándar.

La métrica de ajuste usada es la cantidad de varianza explicada (VE) de V por V_{est} , donde $V_{est} = W_{est} \times H_{est}$. La iteración continua hasta que el cambio en la varianza explicada en $k = 200$ iteraciones consecutivas es menor que una tolerancia $\varepsilon = 1 \times 10^{-5}$.

También hay que elegir el número de sinergias a extraer, (columnas de W), para ello se ha utilizado el método de validación cruzada [9].

Este método consiste en extraer sinergias para cada número de sinergias entre 1 y un máximo que nunca excede el número de músculos medidos (13 en este trabajo), pues las sinergias se obtienen mediante técnicas de reducción de dimensión, ya que se supone que representan información subyacente del sistema de control neural, y por tanto son más compactas que las activaciones musculares por separado. Para cada uno de estas extracciones se calcula la varianza explicada del EMG original (V) por la matriz EMG reconstruida ($W_{mxn} \times H_{nxo}$) a partir de las sinergias, se elige el menor número de

sinergias para las que la varianza explicada supera el 80%, pues a partir de ese valor se obtiene una reconstrucción lo suficientemente buena.

La ecuación de la varianza explicada es la siguiente:

$$VE \equiv 1 - \frac{SS_{res}}{SS_{tot}}, \quad (5)$$

donde SS_{res} es la suma de los cuadrados de los errores entre valor original y predicho, y SS_{tot} es proporcional a la varianza de las muestras originales.

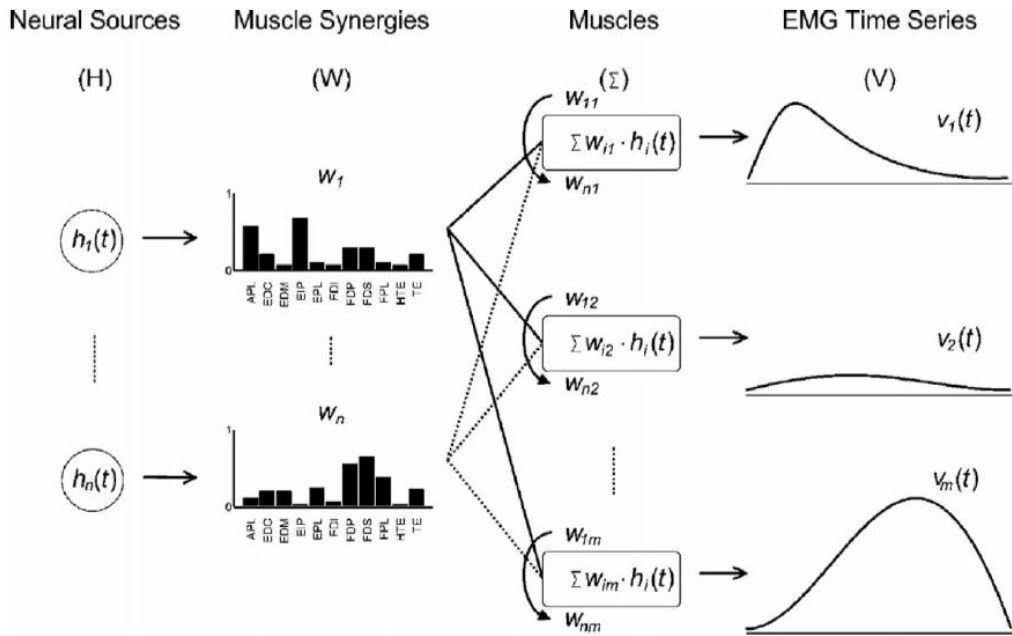


Figura 8. Modelo de combinación de sinergias. Las entradas neurales (H) envían señales de control que actúan como multiplicadores para cada sinergia muscular (W). Los resultados se suman para obtener la actividad EMG observada en cada músculo (V). V la conocemos, y W y H son calculadas mediante NMF.

Capítulo 3

Fatiga

El objetivo último de este trabajo es conseguir desarrollar un detector de fatiga que se pueda integrar en un modelo de músculo, de forma que éste funcione correctamente tanto en condiciones normales como en fatiga.

Para ello es preciso conocer qué se entiende exactamente por fatiga, como se produce, que repercusiones tiene sobre la actividad muscular y como se pueden medir estas repercusiones. En este capítulo se dará respuesta a todas estas preguntas, quedando para el capítulo 7 los resultados obtenidos en los distintos experimentos realizados.

Concepto de Fatiga Muscular

La fatiga muscular expresa la **incapacidad de un órgano o tejido para responder normalmente a un estímulo**. Se corresponde con un estado o sensación de disminución de la capacidad funcional de una parte del cuerpo provocado por un exceso de actividad.

Hay que tener en cuenta, por una parte, la denominada **fatiga central** (considerando estructuras como el cerebro, médula espinal, moto neurona, nervios motores) y una **fatiga periférica**, remitida ahora al músculo esquelético.

La fatiga muscular manifiesta la incapacidad del músculo para mantener una respuesta ante determinadas exigencias de trabajo. En el nivel central, la fatiga se expresa inhibiendo la respuesta motriz, con el fin de que el músculo economice su actuación, con reducción de la excitación. En su vertiente periférica la fatiga se expresa por un decaimiento de la excitación muscular, esto es, del músculo propiamente dicho.

La fatiga muscular aparece cuando el régimen crítico ha sido sobrepasado. Con la fatiga muscular se produce una disminución de la fuerza, así como disminución de la precisión de movimientos; al final se acompaña de temblor.

Producción de fatiga muscular

En el pasado se pensaba que la fatiga era un fenómeno que aparecía a partir de cierto punto de fallo en la capacidad de generación de fuerza, y en consecuencia se estudiaba detectando este punto y analizando la actividad muscular a partir del mismo. Sin embargo, actualmente es bien conocido y aceptado que la fatiga empieza desde el principio de la activación muscular, siendo un **fenómeno continuo**, y por lo tanto hay que analizar la actividad muscular desde el inicio para poder observar la evolución de la fatiga.

Los múltiples mecanismos fisiológicos subyacentes al decrecimiento en la capacidad de producción de fuerza han sido extensamente estudiados [10, 11,12], no se entrará más en detalle en este trabajo.

Repercusiones de la fatiga

Conforme va apareciendo la fatiga se pueden observar una serie de cambios en la señal EMG, que se han ido recogiendo en diferentes trabajos [9,15,16,20]. Para compensar por la pérdida en la capacidad de producción de fuerza se produce un **incremento en la amplitud** del EMG. Además el **espectro de la señal se desplaza hacia frecuencias más bajas** con la fatiga, haciendo que disminuyan la frecuencia mediana y la frecuencia media (figura 9).

Adicionalmente cuando se está realizando un ejercicio repetitivo (flexiones de bíceps por ejemplo) se observa un decaimiento en la amplitud del movimiento (figura 10), debido a la ya mencionada incapacidad del músculo para mantener la respuesta en presencia de fatiga. Este decaimiento en la amplitud de movimiento será usado como medida de capacidad de generación de fuerza o power output en este trabajo (ver capítulo 7).

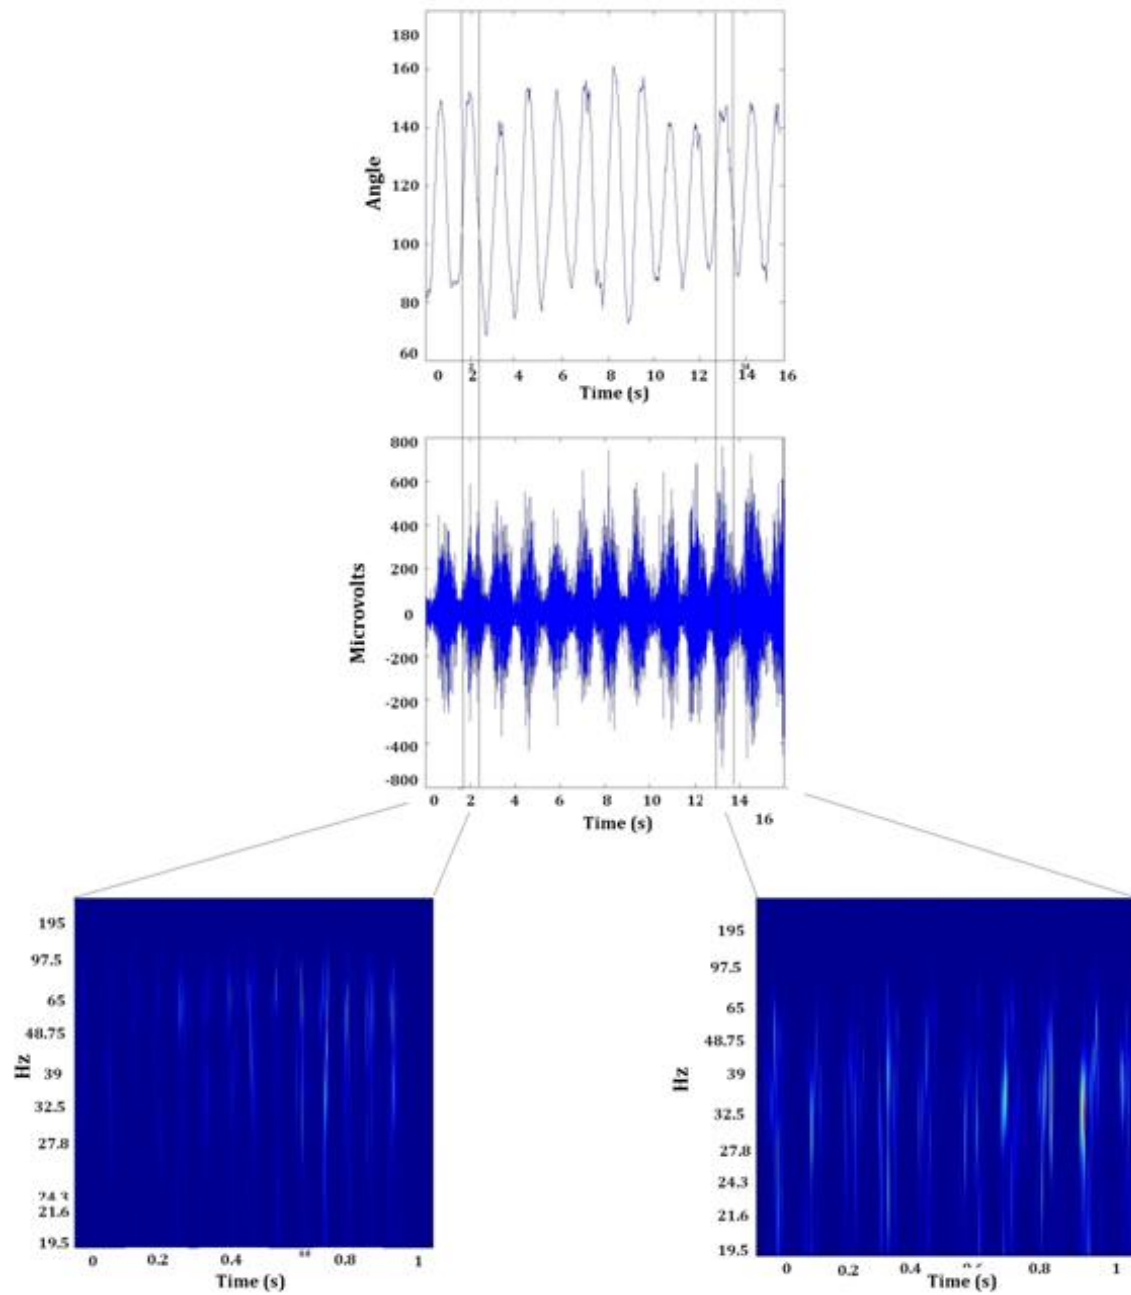


Figura 9. Cambios en el EMG debidos a fatiga. La amplitud de la señal EMG aumenta y el espectro se desplaza hacia frecuencias más bajas. Obsérvese también la reducción en la amplitud del movimiento (imagen superior). El espectro aquí mostrado se ha obtenido mediante análisis wavelet (ver más adelante)




Figura 10. Cambios en la amplitud debido a fatiga.

Análisis de la señal EMG

En primer lugar hay que hacer una distinción entre los dos tipos de fatiga existentes en este ámbito, **fatiga isométrica** y **fatiga dinámica**.

La fatiga isométrica es la causada por aquellos ejercicios en que el músculo permanece estático, sin acortarse ni alargarse, pero aunque permanece estático genera tensión. Un ejemplo de la vida cotidiana sería cuando llevamos a un chico en brazos, los brazos no se mueven, mantienen al niño en la misma posición y generan tensión para que el niño no se caiga al suelo. No se produce ni acortamiento ni alargamiento de las fibras musculares.

La fatiga dinámica es la causada por ejercicios dinámicos, que son lo contrario a los ejercicios isométricos, es decir aquellos ejercicios en que varía la longitud de las fibras musculares y el ángulo de la articulación.

Es importante hacer esta distinción debido a que ambos tipos de fatiga generan diferentes tipos de señales EMG. Mientras que la fatiga isométrica produce señales estacionarias que pueden ser analizadas mediante métodos frecuenciales convencionales

como la Transformada de Fourier, la fatiga dinámica produce señales no estacionarias que tienen que ser analizadas utilizando técnicas tiempo-frecuenciales. Este trabajo se ha centrado en el estudio de la fatiga dinámica, la más interesante, puesto que prácticamente todos los ejercicios realizados en rehabilitación (o en cualquier otro campo) son de naturaleza dinámica.

El primer paso pues es determinar la técnica tiempo-frecuencial a utilizar para el análisis de la señal EMG, siguiendo estudios previos en los que se comparaban diferentes técnicas [13,14] se ha utilizado la transformada *wavelet* continua, pues es la que obtiene mayor precisión y exactitud. Una explicación detallada de la transformada wavelet se puede encontrar en el Anexo VI.

Índices usados en la detección de fatiga

Como se ha indicado antes, los principales cambios que la fatiga produce en la señal son frecuenciales y de amplitud, así pues todos los índices usados se centran en estas características. Los índices elegidos para su estudios se basan en los presentados en otros trabajos [3,14,16], y que ya se ha reportado que pueden dar buenos resultados.

Mean Frequency of the power spectrum (MNF)

Se obtiene a partir del escalograma, que es el cuadrado del valor absoluto de la CWT y representa la distribución de energía de la señal a lo largo de todo el plano tiempo-escala.

La expresión tiempo-escala tiene una expresión equivalente en tiempo-frecuencia, dado que las wavelets, que están bien localizadas en torno a una frecuencia no nula w_0 a escala $s=1$ (la wavelet madre), tienen un relación inversamente proporcional entre escala y frecuencia $s = \frac{w_0}{w}$.

La frecuencia media de la densidad espectral, que es ahora dependiente del tiempo, se redefine para incluir la dependencia del tiempo del contenido frecuencial de la señal EMG basada en la CWT. La frecuencia media instantánea de la densidad espectral se define como:

$$\text{IMNF}(t) = \frac{\int_0^F \omega P(t, \omega) d\omega}{\int_0^F P(t, \omega) d\omega} \quad (10)$$

Donde F es la frecuencia de Nyquist y $P(t, \omega)$ es la densidad espectral dependiente del tiempo (el escalograma).

Finalmente se establece una ventana de análisis del escalograma para calcular un IMNF medio o MNF. Es decir se toma el valor medio cada 'ventana' muestras de IMNF. La MNF disminuye cuando aparece fatiga.

Median Frequency (F_{med})

Calculada numéricamente de la siguiente ecuación:

$$\int_{f_1}^{F_{med}} PS(f) \cdot df = \int_{F_{med}}^{f_2} PS(f) \cdot df, \quad (11)$$

donde $PS(f)$ es el espectro de potencia de la señal calculado mediante la transformada de Fourier (pese a las condiciones no estacionarias de la señal, algunos autores han demostrado su validez en ejercicios dinámicos de alta intensidad [15]) $f_1 = 8\text{Hz}$ y $f_2 = 500\text{Hz}$ (determinado por el ancho de banda de la señal EMG[16]). Disminuye con la fatiga.

Dimitrov Spectral Index (FI_{nsm5})

Un parámetro relativamente reciente (2006) propuesto por Dimitrov y que se ha registrado como un indicador fiable de fatiga [16] definido por:

$$FI_{nsm5} = \frac{\int_{f_1}^{f_2} f^{-1} \cdot PS(f) \cdot df}{\int_{f_1}^{f_2} f^5 \cdot PS(f) \cdot df}, \quad (12)$$

donde $PS(f)$ es el espectro de potencia de la señal calculado mediante la transformada de Fourier, $f_1 = 8\text{Hz}$ y $f_2 = 500\text{Hz}$. Este índice construido como el ratio entre el momento de orden -1 y el momento de orden 5 representa en que rango frecuencias se producen más cambios. El momento de orden -1 (numerador) enfatiza cambios en frecuencias bajas y muy bajas y el momento de orden 5 (denominador) enfatiza los

cambios en altas frecuencias. Como hemos dicho la frecuencia de la señal disminuye con la fatiga, por lo tanto habrá más cambios en frecuencias bajas y menos en altas, haciendo que el momento de orden -1 aumente y el momento de orden 5 disminuya, es por eso que este índice aumenta con la fatiga.

Root mean square (RMS)

Calculado como la raíz cuadrada de la media del cuadrado de los valores de la señal. Aumenta con la fatiga.

Zerocrossing(ZC)

Número de veces que la señal pasa por amplitud 0, disminuye con la fatiga. Se calcula como

$$ZC = \sum_{i=1}^N \text{sgn}(-x_i x_{i+1})$$

$$\text{sgn}(x) = \begin{cases} 1 & \text{si } x > 0 \\ 0 & \text{en caso contrario} \end{cases} \quad (13)$$

donde x_i es el valor de la señal EMG en el instante i .

Sinergias

Se estudiarán las sinergias como método de predicción de fatiga, para ello hay que comprobar si varían o no con la fatiga. La técnica usada para cuantificar esta variación es el producto escalar normalizado [19], que se define por:

$$S = w_1^T \cdot w_2 ,$$

donde w_1^T y w_2^T son dos vectores sinergias normalizados, es decir columnas de la matriz W de sinergias. Este producto nos define una similaridad que va desde 0 a 1.

Capítulo 4

Algoritmo de detección de fatiga

El problema que se nos plantea, es el de dada una muestra de EMG, es decir un segmento de señal EMG, distinguir si esa muestra representa que el sujeto está en estado de fatiga o no, es decir **clasificar** cada muestra de EMG que recibimos en el estado de fatiga correcto, necesitamos un modelo que **aprenda** las características inherentes a cada estado de fatiga.

Nuestro objetivo es entrenar un modelo para que aprenda a clasificar muestras de EMG en los diferentes estados de fatiga. El modelo no trabajará directamente con el EMG, si no que utilizará como parámetros los indicadores que mejor resultado den (extraídos a partir de este EMG) de los presentados en el capítulo anterior (ver capítulo 7). Existen dos principales métodos para el aprendizaje: Aprendizaje supervisado y aprendizaje no supervisado.

El aprendizaje supervisado se usa cuando se dispone de los datos de entrenamiento y la clase esperada para cada uno de estos datos (Ej. Queremos clasificar distintas frutas a partir de fotos, ya sabemos a priori la clase de fruta de cada foto), pero la función que proporciona dichas salidas para los datos de entrenamiento es desconocida. El objetivo del aprendizaje supervisado es descubrir una función que aproxime la función real lo mejor posible, generalmente por métodos de minimización de error mediante bucle cerrado. Esto es se establece una función inicial y se va refinando comparando los resultados obtenidos con los esperados.

El aprendizaje no supervisado se usa cuando sólo se dispone de las entradas, o datos de entrenamiento, y no se sabe a priori la 'etiqueta' o clase correspondiente a cada dato. El objetivo es descubrir estructuras o agrupaciones en los datos, de forma que aquellos

datos que presenten características similares produzcan la misma salida. En nuestro caso, dada una muestra de EMG no podemos saber a priori si el sujeto está fatigado o no, pues como se ha dicho en el capítulo 2 el EMG puede verse afectado por multitud de factores. Además no hay establecidos umbrales para los indicadores de fatiga presentados que puedan tomarse como medida absoluta del estado de fatiga, por lo tanto es necesario utilizar un método de aprendizaje no supervisado.

El enfoque usado para el algoritmo es probabilista, pues se ha visto que puede funcionar con alta precisión [17]. El sistema se divide en dos fases: **Entrenamiento** y **Validación**. Durante el entrenamiento el algoritmo aprende la distribución de los datos respecto a la fatiga, y en la validación se comprueba el funcionamiento del algoritmo con datos que no se han usado para entrenar, y por lo tanto el algoritmo no 'ha visto'.

Para el entrenamiento se han usado los datos de los experimentos de la sesión 2 (ver capítulo 6). La idea principal es que el algoritmo aprenda las variaciones inherentes a la fatiga para poder establecer una serie de niveles de fatiga, a cada uno de los cuales se le asociará un modelo de músculo (ver capítulo 5). Aquí es donde entran en juego los parámetros mostrados en el apartado anterior, pues será la información utilizada por el algoritmo de aprendizaje para establecer dichos niveles. El objetivo es discriminar tantos niveles de fatiga como sea posible.

Para la validación se han usado los datos de los experimentos de la sesión 1 (ver capítulo 6), los resultados se pueden consultar en el capítulo 7.

Evaluación de la fatiga muscular

Los índices finalmente utilizados en el algoritmo han sido:

- Frecuencia Media (MNF)
- Frecuencia Mediana (Fmed)
- Índice espectral de Dimitrov (FI_{nsm5})
- Zerocrossing(ZC)

La razón de esta elección se puede consultar en el capítulo 7, pero básicamente se han elegido aquellos parámetros que muestran una clara tendencia (creciente o decreciente según el índice) conforme aparece la fatiga.

Con estos índices se puede definir un vector de características S , que puede calcularse en cada segmento temporal para cada músculo. El vector de características para cada músculo i , para cada segmento temporal m se define por:

$$S_m^{(i)} = \left[MNF_m^{(i)} Fmed_m^{(i)} FI_m^{(i)} ZC_m^{(i)} \right] \quad (14)$$

El segmento temporal simplemente indica el tamaño de ventana elegido para el análisis de la señal. En este trabajo la ventana es de 420 ms o 1024 muestras, ya que varios autores recomiendan establecer una ventana de tamaño la potencia de 2 más cercana a la mitad de la frecuencia de sampleo. En nuestro caso esta frecuencia es de 2400Hz, por lo tanto la potencia más cercana es 1024. Para realizar el análisis la señal EMG se divide en segmentos de 420 ms (o 1024 muestras), y en cada uno se calculan los índices mencionados.

Como se ha dicho el propósito del trabajo es cuantificar la fatiga muscular para ser capaces de decidir sobre la condición muscular y elegir el modelo muscular adecuado dependiendo del nivel de fatiga. Es decir se necesita una medida de fatiga $f^{(i)}$ para cada músculo i , de forma que se puedan definir una serie de estados de fatiga:

$$F^{(i)} = \{f_1^{(i)}, f_2^{(i)}, \dots, f_n^{(i)}\} \quad (15)$$

Donde n es el número de estados de fatiga para el músculo i .

Con objetivo de definir el nivel de fatiga para el músculo i en cada segmento temporal m , de acuerdo con el vector de características $S_m^{(i)}$, necesitamos calcular la probabilidad a posteriori del músculo de estar en el estado de fatiga $f_j^{(i)}, j = 1, \dots, n$, dado $S_m^{(i)}$, es decir $P(f_j^{(i)} | S_m^{(i)})$. Esto se logra mediante el teorema de Bayes, con el que podemos definir la siguiente ecuación:

$$P(f_j^{(i)} | S_m^{(i)}) = \frac{p(S_m^{(i)} | f_j^{(i)}) P(f_j^{(i)})}{p(S_m^{(i)})}, \quad (16)$$

donde $p(S_m^{(i)} | f_j^{(i)})$ es la función de densidad de probabilidad (*probability density function*, PDF) del vector de características $S_m^{(i)}$ dado el estado de fatiga $f_j^{(i)}$, $P(f_j^{(i)})$ es la probabilidad a priori de que el estado de fatiga sea $f_j^{(i)}$ y

$$p(S_m^{(i)}) = \sum_{j=1}^n p(S_m^{(i)} | f_j^{(i)}) P(f_j^{(i)}), \quad (17)$$

es el factor que garantiza que todas las probabilidades a posteriori sumen uno. Los n estados de fatiga para cada musculo i se consideran igualmente probables a priori:

$$P(f_1^{(i)}) = P(f_2^{(i)}) = \dots = P(f_n^{(i)}) = \frac{1}{n} \quad (18)$$

Sin embargo la PDF del vector de características $S_m^{(i)}$ dado el estado de fatiga $f_j^{(i)}$, $p(S_m^{(i)} | f_j^{(i)})$, necesita ser computado. Para esto se han utilizado los datos de la sesión 2 de experimentos, sobre los que se ha usado la técnica de *Finite Mixture Models*, que proporciona una aproximación matemática al modelado estadístico de una amplia variedad de fenómenos aleatorios [17].

Concretamente, en este trabajo se ha optado por usar *Gaussian Mixture Model* (GMM) para modelar la densidad multivariable del vector de características, puesto que es bastante común en la práctica asumir que las densidades a tratar son Gaussianas. Por lo tanto podemos definir la PDF del vector de características como:

$$p(S_m^{(i)}) = \sum_{h=1}^g \pi_h \varphi_h(S_m^{(i)}, \mu_h, \Sigma_h), \quad (19)$$

donde $\varphi(S_m^{(i)}, \mu_h, \Sigma_h)$ representa un función de densidad Gaussiana multivariable con media μ_h , covarianza Σ_h y $\pi = [\pi_1 \dots \pi_g]$ el vector de pesos de la mixtura.

Usando los datos de entrenamiento mencionados, los parámetros de la GMM (π, μ, Σ), se ajustan mediante el algoritmo *Expectation Maximization* (EM) [17].

Básicamente lo que hace este algoritmo es agrupar los datos similares en torno a clusters (cada cluster es una componente gaussiana g), para ello inicializa aleatoriamente cada una de las componentes gaussianas del modelo e iterativamente va actualizando sus parámetros (media y covarianza), en base a una función de verosimilitud del modelo, hasta llegar a un punto de convergencia. En la figura 11 se puede observar el proceso.

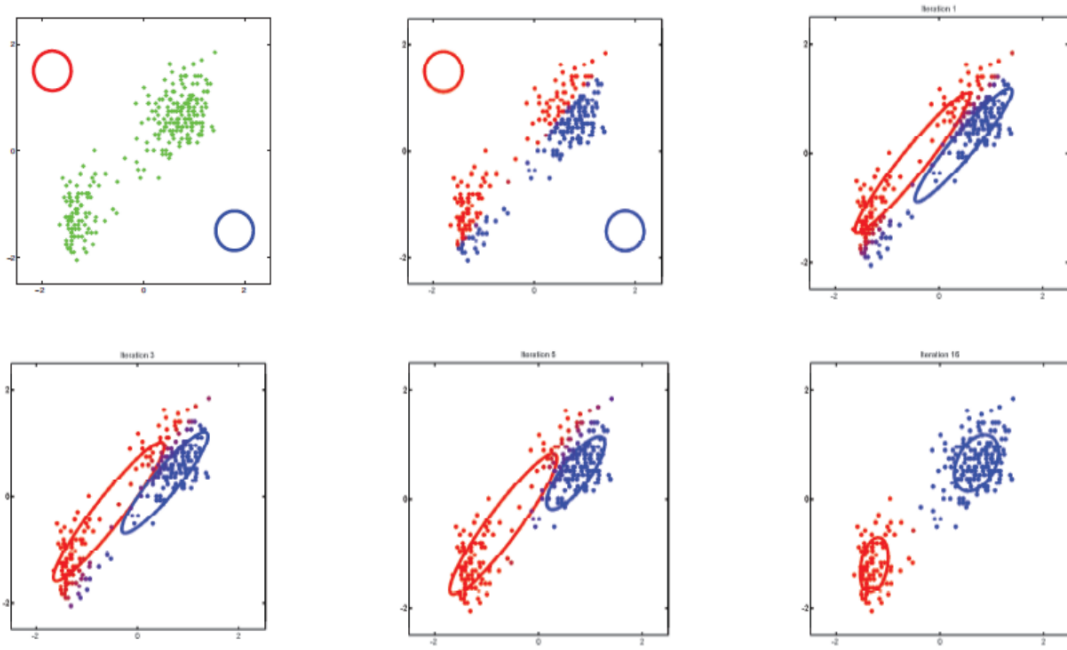


Figura 11. Funcionamiento de EM. En este ejemplo se muestra el funcionamiento de EM para 2 clusters (rojo y azul). Inicialmente las gaussianas se inicializan aleatoriamente (arriba izquierda) y conforme pasan las iteraciones estas gaussianas se van ajustando a los datos hasta llegar al punto de convergencia (abajo derecha).

Estos clusters se pueden entender como los diferentes niveles de fatiga $f_j^{(i)}$ mencionados anteriormente, ya que los datos modelados (los vectores de características) varían con la fatiga, y por lo tanto datos de niveles de fatiga similares tenderán a agruparse en el mismo cluster.

El número de clusters se ha determinado como un compromiso entre la verosimilitud del modelo y un número suficiente de clusters (niveles de fatiga) para poder hacer una clasificación más 'fina' que fatiga o no fatiga, observando la distribución de los datos (ver capítulo 7).

Por lo tanto después del periodo de entrenamiento se puede asignar un nivel de fatiga a cada músculo i en cada segmento temporal m . Para cada músculo i se computa el vector de características $S_m^{(i)}$, luego para cada uno de los j niveles de fatiga, la probabilidad a posteriori del músculo de estar en dicho estado j se puede calcular usando (16), donde :

$$\begin{aligned} p(S_m^{(i)} | f_j^{(i)}) &= \pi_j \varphi_j(S_m^{(i)}, \mu_j, \Sigma_j) \\ P(f_1^{(i)}) &= P(f_2^{(i)}) = \dots = P(f_n^{(i)}) = \frac{1}{g_i} \\ p(S_m^{(i)}) &= \sum_{j=1}^{g_i} p(S_m^{(i)} | f_j^{(i)}) P(f_j^{(i)}) \end{aligned} \quad (20)$$

donde g_i es el número de estados de fatiga para el músculo i . Habiendo calculado $P(f_j^{(i)} | S_m^{(i)})$ para cada nivel de fatiga, podemos decidir el nivel de fatiga del músculo i de acuerdo con la regla de decisión de Bayes:

$$\begin{aligned} \text{decidir } f_k^{(i)} \quad &\text{si } P(f_k^{(i)} | S_m^{(i)}) \geq P(f_h^{(i)} | S_m^{(i)}), \\ h &= 1, \dots, g_i, \quad \text{es decir} \\ f_k^{(i)} &= \underset{k}{\operatorname{argmax}} (P(f_k^{(i)} | S_m^{(i)})), \end{aligned}$$

donde $f_k^{(i)}$ es el estado de fatiga finalmente asignado para el músculo i . Esto nos proporciona el estado de fatiga para cada músculo

Capítulo 5

Integración en un modelo de músculo

Se han dedicado varios trabajos a desarrollar modelos para estimar los pares articulares. Estos modelos son desde 'cajas negras' (redes neuronales) hasta modelos fisiológicos y biomecánicos. En este trabajo hemos partido de un modelo fisiológico clásico. Como se ha comentado en la introducción, la estimación de la fuerza muscular ejercida por las articulaciones del paciente se realiza mediante el Modelo de Hill [27, 28]. Este modelo, basado en el EMG y la cinemática del movimiento, funciona muy bien para condiciones de no fatiga, pero va perdiendo precisión conforme esta aparece, debido a que se altera la relación EMG-Fuerza muscular. Es por eso que se necesita ajustar este modelo si queremos que funcione bien en ambas condiciones. En este capítulo se presenta el método de ajuste propuesto en este trabajo, basado en el algoritmo de detección de fatiga explicado en el capítulo anterior. El significado de todas las variables utilizadas en este apartado se puede encontrar en el glosario.

Una vez el algoritmo de detección de fatiga está entrenado, se inserta en el sistema de estimación de par a partir de medidas EMG de la forma que muestra el esquema de la figura 12.

El proceso de modelado consta de dos fases, calibración en bucle cerrado y funcionamiento en bucle abierto.

A continuación se explicarán los distintos bloques, excepto el detector fatiga que ya ha sido explicado en el capítulo anterior.

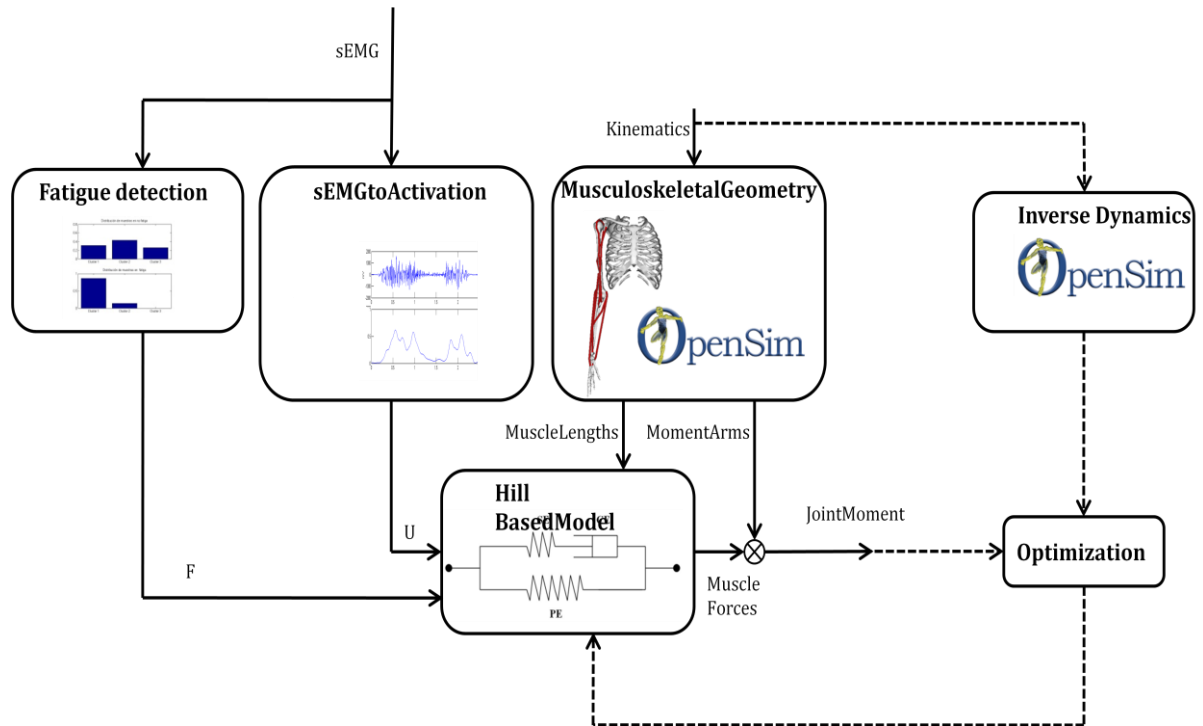


Figura 12. Esquema de funcionamiento del modelo desarrollado.

Transformación de la medida EMG en actividad muscular normalizada

Se describe en el apartado previo 2.1 de la memoria y consiste en una serie de filtrados que transforman la señal en una envolvente lineal (u).

Se han modelado 14 músculos: *Deltoides* (*Anterior* (*DELT3*), *Posterior* (*DELT2*) y *Lateral* (*DELT1*)), *Bíceps Brachii Long head* (*BIClong*), *Bíceps Brachii Short head* (*BICshort*), *Tríceps* (*Largo* (*TRIlong*), *Medial* (*TRImed*) y *Lateral* (*TRIlatt*)), *Brachioradialis* (*BRD*), *Extensor digitorum* (*ECRL*), *Flexor CarpiRadialis* (*FCR*), *Flexor CarpiUlnaris* (*CU*), *Infraspinatus* (*INFRA*) y *PectoralisMajor* (*PECM1*). Del *BICshort* no se ha medido la actividad muscular, pero se ha modelado como la misma del *BIClong* (debido a su cercanía) teniendo en cuenta un factor de escala.

Modelo de músculo basado en el modelo de Hill

Bajo esta perspectiva, el músculo se modela por un elemento contráctil (CE, parte activa, fibra), un elemento elástico y paralelo (PE, parte pasiva), y un elemento elástico en serie con CE (SE, parte pasiva, tendón), figura 13.




Figura 13. Elemento contráctil, elemento serie y paralelo del modelo de Hill.

Lo que hace que se cumplan las siguientes ecuaciones para cualquier músculo i :

$$\begin{aligned} F_{CE_i} &= F_{SE_i} \\ F_i &= F_{CE_i} + F_{PE_i} \end{aligned} \quad (21)$$

La fuerza del elemento contráctil del músculo i (F_{CE_i}) es igual a la fuerza del elemento en serie (F_{SE_i}), y la fuerza total F_i es el sumatorio de la fuerza del elemento contráctil más la fuerza del elemento en paralelo (F_{PE_i}). Las ecuaciones de fuerza de cada elemento presentadas en detalle, son las siguientes (en el Anexo1 se lista el significado de los parámetros y abreviaturas, no obstante, en esta sección se explican las más destacadas por ser los parámetros a optimizar):

$$F_{SE} = \left[\frac{F_{SEmax}}{e^{S_{SE}} - 1} \right] \left[e^{\left(\frac{S_{SE}}{\Delta L_{SEmax}} \Delta L_{SE} \right)} - 1 \right] \quad (22)$$

Donde S_{SE} es el factor de forma del elemento en serie y:

$$\begin{aligned} \Delta L_{SEmax} &= 0.03 L_{Ts} \\ F_{SEmax} &= 1.3 \cdot \omega \cdot F_{CEmax} \\ F_{PE} &= \left[\frac{F_{PEmax}}{e^{S_{PE}} - 1} \right] \left[e^{\left(\frac{S_{PE}}{\Delta L_{PEmax}} \Delta L_{PE} \right)} - 1 \right] \end{aligned} \quad (23)$$

Donde S_{PE} el factor de forma del elemento paralelo, L_{CE0} la longitud de fibra óptima, y:

$$\Delta L_{PEmax} = L_{max} - (L_{CE0} + L_{Ts})$$

$$F_{PEmax} = 0.05 \cdot \omega \cdot F_{CEmax}$$

$$F_{CE} = \omega \cdot F_{CEmax} \cdot u \cdot f_l(L_{CE0}) \cdot f_v(V_{CE0}) \quad (24)$$

Siendo u la activación muscular normalizada, α el porcentaje de fibras rápidas del elemento contráctil, F_{CEmax} la fuerza máxima que puede ejercer el elemento contráctil en condiciones de no fatiga y ω el factor que tiene en cuenta el decremento de generación de fuerza muscular con la presencia de fatiga.

Este parámetro ω es el que se modifica en función del nivel de fatiga detectado en cada momento. Debido a que con el detector de fatiga ha sido posible detectar 3 estados de fatiga (ver capítulo 7) genéricos para la población, la adaptación también va a ser genérica en este sentido. Cuando el detector de fatiga estime que no hay fatiga, equivale a $\omega = 1$, con media fatiga $\omega = 0.75$, es decir, el factor hará disminuir la fuerza máxima del músculo en un 25%, y con fatiga $\omega = 0.5$, la fuerza máxima de contracción de la fibra descenderá en un 50%. Los términos f_l y f_v son la relación fuerza-longitud de músculo y fuerza-velocidad de contracción respectivamente, que se pueden expresar de la siguiente forma, y cuyo comportamiento se explica en [29]:

$$f_l(L_{CE0}) = \exp\left(-0.5 \left(\frac{\frac{\Delta L_{CE}}{L_{CE0}} - 0.05}{0.19}\right)^2\right)$$

$$f_v(V_{CE0}) = \frac{0.1433}{0.1074 + \exp\left(-1.3 \sinh\left(2.8 \frac{V_{CE}}{V_{CE0}} + 1.64\right)\right)} \quad (25)$$

Con:

$$V_{CE0} = 0.5(u + 1)V_{CEmax}$$

$$V_{CEmax} = 2L_{CE0} + 8L_{CE0}\alpha \quad (26)$$

El momento neto generado en la articulación del codo es el sumatorio de los momentos individuales generados por cada uno de los músculos que intervienen:

$$\tilde{M}_{neto} = \sum_{i=1}^n F_i r \quad (27)$$

Siendo n el número de músculos considerados, r el brazo de momento de cada músculo para el movimiento coplanario que estamos considerando, y F_i es la fuerza total generada por el músculo i .

Los músculos que se modelan son los ya mencionados, se puede consultar la localización de estos músculos en el Anexo I. El cálculo de las longitudes de músculo y los brazos de momento (cinemática musculoesquelética) se realiza mediante el software OpenSim [25]. Esta plataforma nos permite estudiar las características musculares (longitud de músculo y brazo de momento) durante los movimientos. Una descripción del software puede encontrarse en el Anexo II.

Calibración del modelo

Este modelo tiene un enfoque muy biomecánico y hay parámetros que es muy difícil de hallar para cada persona, haciendo necesaria una calibración individual para cada sujeto. Durante el proceso de calibración, se utiliza la dinámica inversa obtenida mediante OpenSim que nos proporciona el valor teórico de los pares articulares a partir de la cinemática del movimiento (ver Anexo II), como referencia de par con la que comparar. En cada iteración de la calibración la estimación obtenida mediante el modelo de Hill a partir del EMG, la cinemática y el nivel de fatiga detectado se compara el valor con la dinámica inversa y el error entre ambas se utiliza para realimentar y reajustar el sistema. El ajuste se realiza mediante un procedimiento de optimización que proporciona los parámetros óptimos del modelo.

Se utiliza un algoritmo no lineal ‘trust-region-reflective’[29] disponible en el *Matlab Optimization toolbox* para resolver este problema de ajuste de curvas mediante mínimos cuadrados ('lsqcurvefit' "función de Matlab).

Con un modelo completo experimental de la extremidad superior [25,26], se obtuvieron los parámetros genéricos, para el percentil 50 de un varón de 170 cm de altura, de L_{\max} , L_{C0} , L_{TS} , y F_{cemax} ,

Muscle		1	2	3	4	5	6	7
		L_{max} [cm]	L_{ce_0} [cm]	L_{TS} [cm]	$F_{ce,max}$ [N]	α [%]	S_{pe}	S_{se}
1	DELT3	19.9392	13.67	3.8	259.88	58	9	2.8
2	DELT2	21.9046	10.78	10.95	1142.6	58	9	2.8
3	DELT1	38.99	9.76	9.3	1142.6	58	9	2.8
4	PECM1	16.1934	14.42	0.28	364.41	58	9	2.8
5	BIClong	45.53	11.57	27.23	624.3	56	9	2.8
6	BICshort	41.6755	13.21	19.23	435.56	56	9	2.8
7	TRIl lat	21.47	11.38	9.8	624.3	66	10	2.3
8	TRIl long	32.57	13.4	14.3	798.52	66	10	2.3
9	TRIl med	20.233	11.38	9.08	624.3	66	10	2.3
10	ECRL	34.49	8.1	22.4	304.89	50	8	3
11	FCR	32.84	6.28	24.4	73.96	58	6	3
12	BRD	30.6	17.3	13.3	261.3	56	9	2.8
13	FCU	31.6	5.1	26.5	128.9	58	6	3
14	INFRA	10.7	7.6	3.1	1210.8	58	9	2.8

Tabla 1. Parámetros genéricos obtenidos. Marcados en verde los parámetros a optimizar.

La Tabla 2 representa los parámetros del modelo que se optimizan y los límites utilizados. Los parámetros α , S_{PE} , y S_{SE} fueron tomados de [28], al igual que algunos de los valores sobre los límites del intervalo inferior y superior de los parámetros. En total nuestro modelo contiene 72 parámetros que optimizar, 5 para cada músculo y 2 factores globales (el factor de activación del músculo BICshort y un factor de escala geométrico).

Parámetro	Límites	Característica
L_{ce_o}	[0.8,1.2]	por músculo
$F_{ce_{max}}$	[0.5,1.5]	por músculo
α	[0.5,1.5]	por músculo
S_{PE}	[0.8,1.2]	por músculo
S_{SE}	[0.8,1.2]	por músculo
f_{BIC}	[0.8,1.2]	Global
f_{geom}	[0.8,1.2]	Global

Tabla 2. Límites superiores e inferiores impuestos en el proceso de optimización

Una vez calibrado, el modelo pasa a funcionar en bucle abierto, dejando de utilizar la dinámica inversa de OpenSim para realimentar el sistema, y utilizando únicamente el modelo de Hill.

Capítulo 6

Experimentación

Este trabajo se sustenta principalmente en la experimentación, pues es necesario validar toda la teoría y los algoritmos mostrados, para comprobar que funcionen en un entorno real. En este capítulo se presentarán los experimentos realizados, los sujetos que participaron en cada experimento y el equipo y protocolos usados para llevarlos a cabo.

6.1 Sujetos

Un total de 9 sujetos se han presentado voluntarios para los experimentos, en la tabla 3 se expone una breve ficha de cada sujeto en la que se incluyen los principales datos fisiológicos, así como los experimentos en los que ha participado y la carga de las pesas para cada ejercicio (Bíceps, Tríceps, Deltoides) si participó en la sesión 1.

SUJETO	SEXO	PESO [Kg]	ALTURA [m]	EDAD	SESIÓN	PESA BIC [Kg]	PESA TRIC [Kg]	PESA DEL [Kg]
Sujeto 1	Masculino	78	1.84	23	2	-	-	-
Sujeto 2	Masculino	66	1.76	23	1,2	5	3	3
Sujeto 3	Femenino	47	1.52	29	1,2	3	3	1
Sujeto 4	Masculino	78	1.80	24	2	-	-	-
Sujeto 5	Femenino	48	1.78	25	1	3	3	1
Sujeto 6	Masculino	76	1.85	23	1	5	3	6
Sujeto 7	Masculino	70	1.79	25	1,2	5	3	3
Sujeto 8	Femenino	62	1.64	28	1	3	3	1
Sujeto 9	Masculino	80	1.71	37	1,2	5	3	3

Tabla 3.Sujetos participantes en los experimentos

6.2 Equipo y adquisición de datos

Se han usado sensores EMG KENDAL Meditrace 200, colocados en una configuración bipolar conforme a las recomendaciones SENIAM (European project: Surface EMG for Non-Invasive Assessment of Muscles [18]) en los 13 músculos anteriormente mencionados. Concretamente se han medido el ver el anexo de músculos medidos para más información.



Figura 14.Equipo usado en la experimentación. Izquierda equipo amplificador gTec, centro cámara kinect y derecha electrodos y cables de conexión.

Las señales se han amplificado mediante un sistema comercial gTec. El EMG se ha digitalizado a una frecuencia de 2.4KHz, y se le ha aplicado un filtro paso-banda de 5/500Hz y un notch filter a 50Hz. Es necesario previamente a la colocación de los electrodos, limpiar y rasurar la zona de piel en que se colocará cada electrodo para tener una mejor medida. Las señales se capturaron y filtraron mediante un sistema de procesamiento *online* de alta velocidad Simulink de gTec, con configuración bipolar. Para la captura de las cinemáticas de los movimientos se ha utilizado una cámara kinect. Los diferentes instrumentos usados se pueden ver en la figura 14.

6.2.1 Kinect

Además de la información EMG, también se ha utilizado información cinemática para el análisis de los resultados, pues proporciona información sobre la posición y velocidad del brazo del sujeto durante el ejercicio, que resulta de gran utilidad a la hora de analizar los resultados obtenidos de la señal EMG o complementarlos.

De hecho, como se verá en el capítulo 7, se ha establecido una relación entre la amplitud del movimiento y la capacidad de generación de fuerza del sujeto a la hora de validar los resultados obtenidos para cada indicador de fatiga, cosa imposible si no se cuenta con la información cinemática. Es en la obtención de esta información cinemática donde entra en juego Kinect. Una explicación detallada de su funcionamiento se puede ver en el Anexo V. Lo importante es la información cinemática que proporciona, en la figura 15 se puede ver un ejemplo de cinemática para un ejercicio de Bíceps. Esta muestra la evolución del ángulo del brazo para cada instante temporal. Esta información es la que necesita el modelo de músculo como entrada.




Figura 15. Información cinemática proporcionada por kinect.

6.3 Protocolo experimental

Se han realizado dos sesiones de experimentos: los datos recogidos en la sesión 1 se han usado para estudiar la evolución de los índices de fatiga y validar el algoritmo de detección de fatiga y su integración en el modelo de músculo, y los datos de la sesión 2 para entrenarlo. A continuación se exponen ambos protocolos experimentales, así como los sujetos que participaron en cada uno.

Sesión 1 de Experimentos

Participantes: Sujetos 2,3,5,6,7,8,9.

Objetivo: Validar la idoneidad de los índices del capítulo 3 y obtener datos de validación para el algoritmo de detección de fatiga y el modelo de músculo. Grabar tanto EMG como cinemática (Kinect) para que esta nos sirva como referencia a la hora de validar los datos, pues se utilizará la aproximación amplitud del movimiento-capacidad de generación de fuerza. Se quieren obtener datos muy diferenciados, unos en condiciones de no fatiga y otros en fatiga, por eso se ha incluido una sesión de fatiga isométrica entre los dos ejercicios que se ha realizan de cada músculo.

Protocolo: Se realizarán tres tipos de ejercicios cada uno destinado a estimular una zona muscular concreta, flexiones de bíceps, tríceps y hombro. Las figuras 16, 17 y 18 muestran las posiciones para cada ejercicio. La posición básica del sujeto es común a los tres ejercicios, permanecerá de pie, erguido con los brazos ligeramente separados del cuerpo. Cada Sujeto utilizará una pesa, elegida por el mismo atendiendo a su fisiología y tonificación muscular, para realizar los ejercicios, la carga de dicha pesa se puede consultar en el apartado 6.1.

El protocolo completo detallado es el siguiente:

1. *Sesión de máxima contracción voluntaria (MCV) para el bíceps, tríceps y hombro:* Para el bíceps, en la posición anteriormente detallada, el sujeto flexionará el antebrazo con oposición de otra persona, ejerciendo la máxima fuerza posible. Para el tríceps, en la posición base, pero con el tronco ligeramente inclinado hacia delante y el brazo estirado hacia atrás, el sujeto flexionará el antebrazo con oposición de otra persona. Y para el hombro en la

posición base, el sujeto levantará el brazo lateralmente con oposición de otra persona, ejerciendo la máxima fuerza posible. En los tres ejercicios se realizarán tres repeticiones de 3 segundos con 2 segundos de descanso entre cada una. Esta sesión nos sirve para obtener la amplitud referencia respecto de la que normalizaremos el nivel de activación del resto de ejercicios (ver capítulo 2).

2. *Sesión dinámica de no fatiga del bíceps*: En la posición base el sujeto flexionará el antebrazo hasta que forme unos 15-20° con el hombro. Se realizaran 15 repeticiones a velocidad constante.
3. *Sesión de fatiga isométrica del bíceps*: El sujeto fatigará el bíceps, manteniendo el brazo flexionado a 90° hasta que no pueda aguantar más. Las sesiones de fatiga isométrica para cada músculo no se grabarán, porque tienen como único objetivo fatigar el respectivo músculo a estudiar para la siguiente fase.
4. *Sesión dinámica de bíceps fatigado*: Se repite el ejercicio (2) después de 30 segundos de descanso.

3 minutos de descanso

5. *Sesión dinámica de no fatiga del tríceps*: En la misma posición anterior el sujeto flexionará el antebrazo hacia atrás. Se realizaran 15 repeticiones a velocidad constante.
6. *Sesión de fatiga isométrica del tríceps*: El sujeto fatigará el tríceps, manteniendo la posición de máxima tensión del ejercicio anterior (brazo estirado hacia atrás).
7. *Sesión dinámica de tríceps fatigado*: Se repite el ejercicio (7) después de 30 segundos de descanso.

3 minutos de descanso

8. *Sesión dinámica de no fatiga del hombro*: En la posición base el sujeto el sujeto levantará el brazo lateralmente hasta que forme 90° con el tronco. Se realizaran 15 repeticiones a velocidad constante.
9. *Sesión de fatiga isométrica del hombro*: El sujeto fatigará el hombro, manteniendo la posición de máxima tensión del ejercicio anterior (brazo a 90° con el tronco).

10. *Sesión dinámica de hombro fatigado*: Se repite el ejercicio (12) después de 30 segundos de descanso.

Sesión 2 de Experimentos

Participantes: Sujetos 1,2,3,4,7,9

Objetivo: Obtener datos para el entrenamiento del algoritmo de detección de fatiga. En este caso el ejercicio será continuo, a diferencia del protocolo anterior, pues nos interesa tener datos sobre todas las fases de la fatiga, para poder realizar en entrenamiento correcto.

Protocolo: Se realizarán tres tipos de ejercicios cada uno destinado a estimular una zona muscular concreta, flexiones de bíceps, tríceps y hombro. Las figuras 16, 17 y 18 muestran las posiciones para cada ejercicio. Cada Sujeto utilizará una pesa común de 1kg para realizar los ejercicios.

El protocolo detallado es el siguiente:

1. *Sesión de Bíceps*: En la posición base el sujeto flexionará el antebrazo hasta que forme unos 15-20° con el hombro. Se realizarán repeticiones hasta que el sujeto llegue al punto de fallo, es decir, no pueda hacer más.
2. *Sesión de Tríceps*: En la posición base, pero con el tronco ligeramente inclinado hacia delante y el brazo estirado hacia atrás, el sujeto flexionará el antebrazo hacia atrás. Se realizarán repeticiones hasta que el sujeto llegue al punto de fallo, es decir, no pueda hacer más.
3. *Sesión de Hombro*: En la posición base el sujeto el sujeto levantará el brazo lateralmente hasta que forme 90° con el tronco. Se realizarán repeticiones hasta que el sujeto llegue al punto de fallo, es decir, no pueda hacer más.

Sólo han participado 6 sujetos en este experimento para poder contar con los datos de tres sujetos que no han sido utilizados en el entrenamiento del algoritmo de detección de fatiga para realizar la validación del mismo.




Figura 16. Posición que debe mantener el sujeto durante el ejercicio de bíceps. Izquierda posición inicial. Derecha posición final.



Figura 17. Posición que debe mantener el sujeto durante el ejercicio de tríceps. Izquierda posición inicial. Derecha posición final.



Figura 18. Posición que debe mantener el sujeto durante el ejercicio de deltoides. Izquierda posición inicial. Derecha posición final.

Capítulo 7

Resultados

En este capítulo se presentarán los resultados obtenidos para cada uno de los principales apartados trabajados y presentados en esta memoria: Indicadores de fatiga, sinergias musculares, algoritmo de detección de fatiga y el modelo muscular con el algoritmo de detección de fatiga integrado.

7.1 Indicadores de fatiga

Se han utilizado los datos de la sesión 1 de experimentos para validar los indicadores de fatiga presentados en el capítulo 3. Para cada ejercicio realizado en dicho experimento (capítulo 6) se ha elegido el músculo 'principal' (el que más fuerza ejerce, y por tanto más se fatiga) para analizar la evolución de los indicadores. Los músculos elegidos han sido: Bíceps Brachii, Tríceps Medial y Deltoides Medio. En esta sección se muestran los resultados para el Bíceps, los resultados del Tríceps y el Deltoides se pueden consultar en el Anexo III.

Hay que tener presente que los indicadores no aportan información absoluta sobre el estado del sujeto, pues se pueden producir cambios en los mismos por diversos factores (velocidad a que se realiza el ejercicio, carga o resistencia con que se realiza, etc.), por lo tanto hay que relacionarlos con la capacidad de generación de fuerza del sujeto (ver capítulo 3). En este trabajo esa capacidad de generación de fuerza (Power output) se ha aproximado por la amplitud (en grados) del movimiento realizado por el sujeto, pues conforme aparece la fatiga el sujeto se ve cada vez más incapaz de realizar el ejercicio de forma completa (Ej. En las flexiones del hombro se deja de subir el brazo hasta que forme 90° con el tronco, disminuyendo el ángulo con la aparición de la fatiga).

En la figuras 19-24 se puede ver la evolución de cada parámetro conforme avanza el ejercicio, así como también la evolución del Power output. Los resultados se muestran en media \pm desviación típica de todos los sujetos.




Figura 19. Evolución del Power Output. Ejercicio del Bíceps. Se muestran las 30 repeticiones realizadas (15 en no fatiga y 15 en fatiga) como porcentaje de cambio desde la primera repetición.




Figura 20. Evolución de log FI (Se toma el logaritmo para que siga una distribución normal [16]). Ejercicio de Bíceps. Se muestran las 30 repeticiones realizadas (15 en no fatiga y 15 en fatiga) como porcentaje de cambio desde la primera repetición.




Figura 21. Evolución de la frecuencia mediana (Fmed). Ejercicio de Bíceps. Se muestran las 30 repeticiones realizadas (15 en no fatiga y 15 en fatiga) como porcentaje de cambio desde la primera repetición.




Figura 22. Evolución de la frecuencia media (MNF). Ejercicio de Bíceps. Se muestran las 30 repeticiones realizadas (15 en no fatiga y 15 en fatiga) como porcentaje de cambio desde la primera repetición.




Figura 23. Evolución del RMS. Ejercicio de Bíceps. Se muestran las 30 repeticiones realizadas (15 en no fatiga y 15 en fatiga) como porcentaje de cambio desde la primera repetición.




Figura 24. Evolución del zerocrossing (ZC). Ejercicio de Bíceps. Se muestran las 30 repeticiones realizadas (15 en no fatiga y 15 en fatiga) como porcentaje de cambio desde la primera repetición.

De este primer análisis se puede observar que los parámetros mostrados efectivamente sufren variaciones (las esperadas para cada uno, ver capítulo 3) conforme avanzan las repeticiones. Sin embargo se muestra la evolución temporal de cada parámetro respecto de si mismo, y como hemos dicho lo más interesante es ver la correlación existente entre cada uno de estos parámetros y el Power output. Esto se muestra en las figuras 25-29 que muestran la distribución conjunta para todos los sujetos de cada parámetro respecto del Power output. Cada asterisco en la figura representa el valor del parámetro respecto del Power output en una de las 30 repeticiones, y cada color representa una persona. Para evaluar el grado de correlación se ha usado el coeficiente de correlación de Pearson (R), que es una medida de la relación lineal entre dos variables aleatorias cuantitativas X, Y , definido por:

$$R_{X,Y} = \frac{cov(X,Y)}{\sigma_X \sigma_Y},$$

donde cov es la covarianza, y σ_X la desviación típica. El valor del índice de correlación varía en el intervalo $[-1,1]$, y su interpretación es la siguiente:

- Si $R = 1$, existe una correlación positiva perfecta. Denominada *relación directa*: cuando una de ellas aumenta, la otra también lo hace en proporción constante.
- Si $0 < R < 1$, existe una correlación positiva.
- Si $R = 0$, no existe relación lineal. Pero esto no necesariamente implica que las variables son independientes: pueden existir todavía relaciones no lineales entre las dos variables.
- Si $-1 < R < 0$, existe una correlación negativa.
- Si $R = -1$, existe una correlación negativa perfecta. El índice indica una dependencia total entre las dos variables llamada *relación inversa*: cuando una de ellas aumenta, la otra disminuye en proporción constante.

Adicionalmente se utiliza otro índice, el p-valor como medida de significancia de la correlación obtenida. Un ejemplo sencillo es el siguiente: supóngase que estamos tratando de determinar si la inteligencia y la altura están relacionadas, entonces empezamos con la 'hipótesis nula' que en este caso es: 'Altura e inteligencia no están relacionadas'. El p-valor es un número, entre 0 y 1 que representa la probabilidad de obtener los datos que tenemos si la hipótesis nula fuera cierta.

Un valor bajo de p-valor indica que la hipótesis nula puede ser rechazada, normalmente este valor se establece en 0.01 o 0.05.




Figura 25. Distribución del log FI respecto del PowerOutput (% de la primera repetición). Ejercicio de Bíceps. R, coef. correlación Pearson y p el p-valor.




Figura 26. Distribución de Fmed respecto del PowerOutput (% de la primera repetición). Ejercicio de Bíceps. R, coef. correlación Pearson y p el p-valor.




Figura 27. Distribución de MNF respecto del Power Output (% de la primera repetición). Ejercicio de Bíceps. R, coef. correlación Pearson y p el p-valor.




Figura 28. Distribución de RMS respecto del Power Output (% de la primera repetición). Ejercicio de Bíceps. R, coef. correlación Pearson y p el p-valor.




Figura 29. Distribución de ZC respecto del Power Output (% de la primera repetición). Ejercicio de Bíceps. R, coef. correlación Pearson y p el p-valor.

De este segundo análisis se han extraído muchas más conclusiones. En primer lugar se ha observado que prácticamente todos los indicadores cambian su comportamiento, o correlación en el ejercicio del tríceps (ver anexo III), es decir que disminuye el grado de correlación, o incluso llega a cambiar la tendencia (creciente-decreciente). Esto puede tener su explicación en que este ejercicio es el técnicamente más complicado de realizar de los tres. Durante la realización de los experimentos se ha observado que varios sujetos no eran capaces de realizar el ejercicio de forma correcta (entiéndase correcta en cuanto a posición del cuerpo y brazo y movimiento a realizar), lo que puede llevar a un desarrollo de fatiga en grupos de músculos diferentes del esperado, o incluso a un bajo desarrollo de fatiga.

También se ha observado que el RMS no ofrece resultados muy fiables, pues sólo en el ejercicio de bíceps sigue la tendencia esperada (creciente con la fatiga), y en este ejercicio el p-valor obtenido indica que la correlación obtenida no es representativa. Los indicadores más robustos parecen ser el MNF y el ZC, pues ambos mantienen la tendencia esperada y un p-valor representativo durante los tres ejercicios. Es interesante resaltar que además de existir una tendencia global, cada sujeto también sigue esa

misma tendencia, demostrando que el uso de estos parámetros se puede extender a distintas personas.

Tras analizar estos resultados, se ha decidido usar como parámetros para el algoritmo de detección de fatiga, el MNF, Fmed, FI y ZC, dejando fuera al RMS por las razones mencionadas.

7.2 Sinergias

Como se ha mencionado en el apartado 2.2, uno de los objetivos de este trabajo es comprobar si una vez obtenidas las sinergias de un sujeto, estas se pueden generalizar a otras condiciones de fatiga. Para ello se han utilizado los datos de la sesión 1 de experimentos, que proporcionan tanto datos en fatiga como en no fatiga, se han extraído sinergias para cada sujeto de las 15 primeras repeticiones (no fatiga) y de las 15 últimas (fatiga). El primer factor a determinar es el número de sinergias extraídas, para ello se ha seguido el método explicado en el capítulo 2, la figura 30 muestra la evolución de la varianza explicada (VE) de la matriz EMG original V por la matriz de EMG reconstruida V_{est} a partir de las sinergias.




Figura 30. Evolución de la varianza explicada para el ejercicio del Bíceps (No fatiga izquierda y fatiga derecha). El resultado se muestra en media \pm desviación estándar para todos los sujetos.

Como muestran estas figuras, el número de sinergias para el que la reconstrucción supera el 80% de varianza explicada para todos los sujetos (hay que tener en cuenta la desviación típica) es tres. Es por ello que es el número de sinergias elegido para el análisis en este trabajo.

En la figura 31 se muestran las tres sinergias obtenidas para no fatiga y para fatiga para el ejercicio del bíceps promediadas para todos los sujetos. Es interesante observar cómo varía la activación de los músculos en las sinergias con los diferentes ejercicios (Anexo III), así por ejemplo en el ejercicio de bíceps los principales músculos reclutados (aquellos con una activación considerable en la sinergia) , son el propio bíceps (Bi), los flexores del brazo (FCR, FCU, ExD, Bra) y el pectoral (Pect), en el ejercicio de hombro los deltoides (DA, DM, DP) y el pectoral (Pect) y para el ejercicio de tríceps se puede apreciar un reclutamiento más disperso, participando la mayoría de los músculos. Esto puede refrendar la observación hecha en el apartado anterior, que afirmaba que el ejercicio de tríceps había sido el más difícil de realizar para los sujetos, y que la mayoría no había conseguido realizar el ejercicio correctamente.

Uno de los objetivos de este trabajo, como ya se ha dicho, es comprobar la generalización de sinergias a diferentes situaciones de fatiga, esto es si las sinergias se mantienen relativamente constantes cuando aparece fatiga.

Para cuantificar este grado de generalización a diferentes grados de fatiga se ha calculado la similaridad, mediante el producto escalar normalizado (PEN), presentando en el capítulo 3, entre las distintas sinergias obtenidas en fatiga (SINxF) y no fatiga (SINxNF) (tabla 4).

	EJERCICIO	PEN
Similaridad SIN1NF y SIN1F	Bíceps	0.97
	Hombro	0.94
	Tríceps	0.92
Similaridad SIN2NF y SIN2F	Bíceps	0.93
	Hombro	0.97
	Tríceps	0.95
Similaridad SIN3NF y SIN3F	Bíceps	0.91
	Hombro	0.95
	Tríceps	0.94

Tabla 4. Similaridad entre sinergias. Resultado del producto escalar normalizado para las sinergias en no fatiga y fatiga.

Como se puede observar PEN es superior en todos los caso a 0.9, por lo que se concluye que las sinergias se pueden considerar constantes en presencia de fatiga. Esto nos lleva a pensar que el sistema de control neural no modifica las estrategias de control en presencia de fatiga, y que se adapta a ella de otra forma, a un nivel mas muscular en base a los resultados obtenidos.

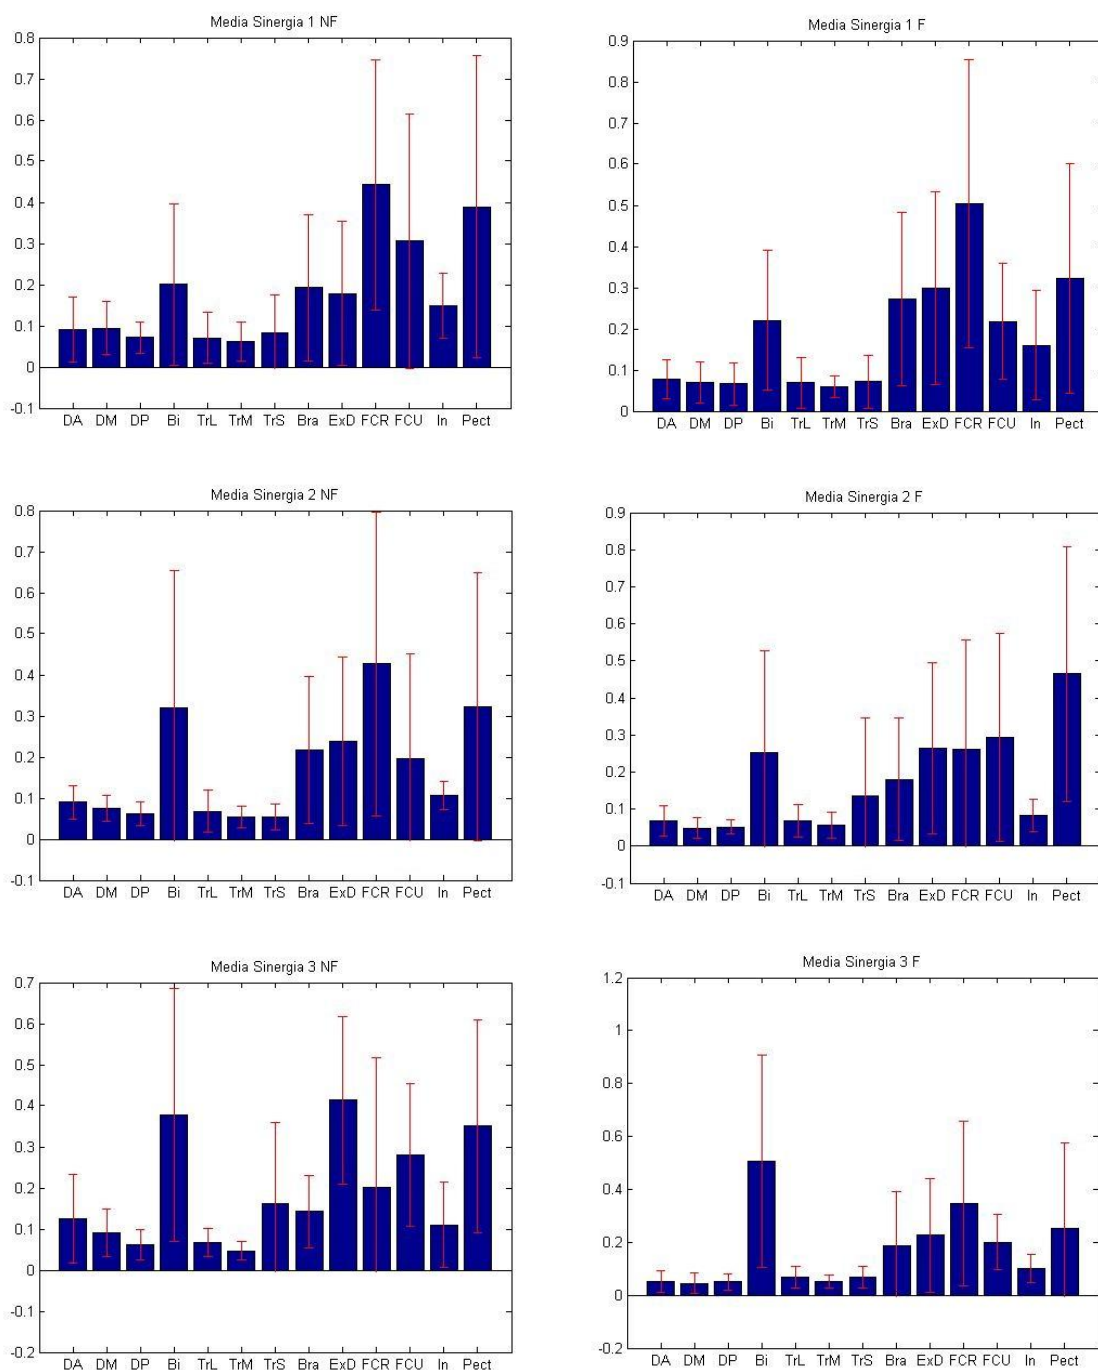


Figura 31. Sinergias obtenidas para el ejercicio del Bíceps. En condición de no fatiga (Izquierda) , y en condición de fatiga (Derecha). El eje de abscisas representa los músculos considerados. Los resultados están en media \pm desviación típica.

7.3 Algoritmo de detección de fatiga

Para entrenar el clasificador se entregan al algoritmo todos los vectores de características de varias personas extraídos a lo largo de todo el ejercicio de la sesión 1. Este tiene que agruparlos (formando clusters) en base a las similitudes entre ellos.

En la figura 32 se muestra la distribución de los datos de entrenamiento para el músculo del Bíceps para los diferentes números de cluster probados. El modelo finalmente seleccionado es el que contiene tres clusters, pues se ha probado experimentalmente que es el que mejor resultados proporciona. Es importante notar que las distribuciones se muestran en 3 dimensiones (ZC, Fmed y FI que es el eje Z, en la perspectiva mostrada no se aprecia) pero el número de indicadores utilizados es 4.

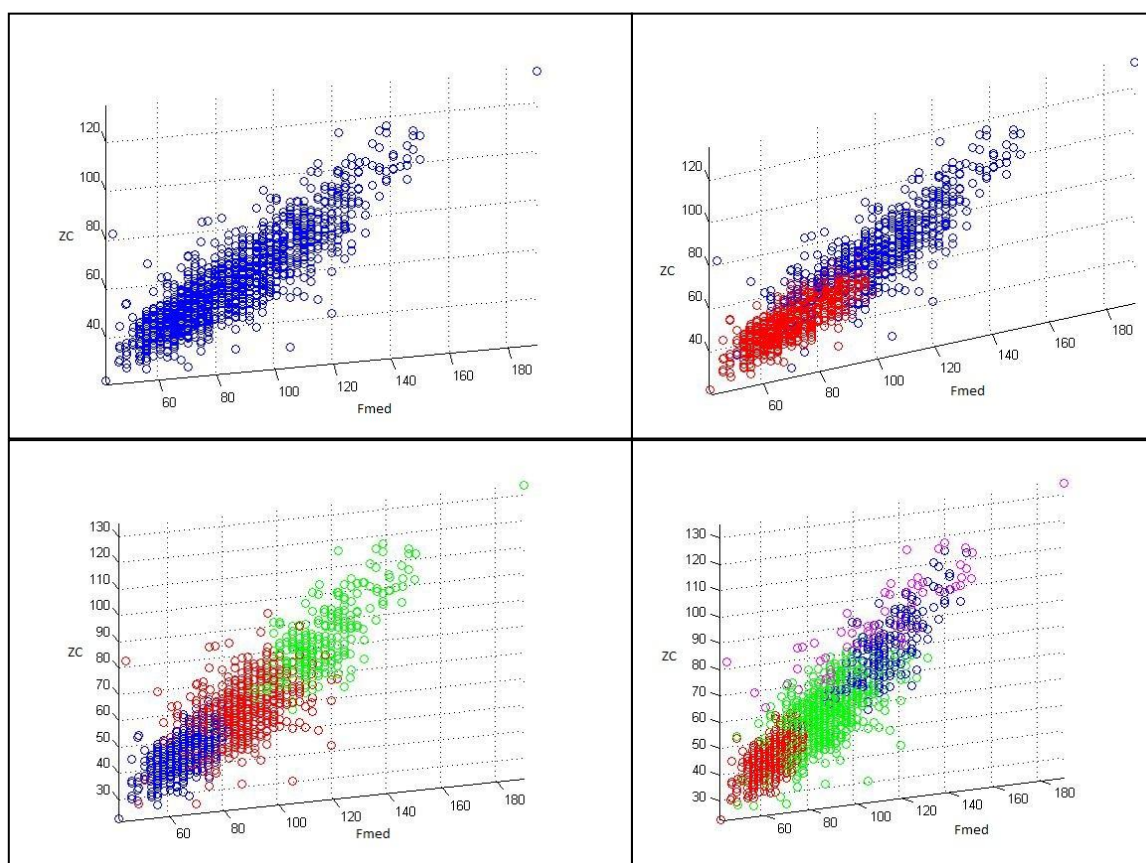


Figura 32. Distribución de los datos para cada n° de clusters. Cada color representa 1 cluster,. Los colores no se conservan de un modelo a otro, es decir el cluster azul en el modelo de 2 clusters no es el cluster azul del modelo de 3 clusters.

Tras realizar el entrenamiento con los datos de la sesión 2 para todos los sujetos y todos los ejercicios, se procede a validar el clasificador con los datos de la sesión 1, ya que podemos conocer con cierta certeza a que estado de fatiga puede pertenecer cada muestra y hacernos una idea del funcionamiento del clasificador.

A continuación se muestran los resultados del clasificador obtenidos para el Sujeto 3 y el Sujeto 6 (figuras 33-34) para el ejercicio del bíceps realizado en la sesión 1 de experimentos. Se ha elegido tanto un Sujeto que participó en la sesión 2, de la que se tomaron los datos para entrenar el clasificador, como de otro que no participó para comprobar la capacidad de generalización del clasificador. Además, son sujetos con muy distintas condiciones fisiológicas (ver tabla 4).

Para realizar la clasificación, se dividen ambas señales EMG (la señal del ejercicio en no fatiga y la señal del ejercicio en fatiga) en ventanas de 1024 muestras, para cada una de estas ventanas se calculan los cuatro indicadores de fatiga seleccionados (ver capítulo 4), que son el dato de entrada para el clasificador.

Cada figura se divide en dos partes, la primera (sección superior) muestra la distribución de estos datos en los diferentes clusters (en tanto por uno) para ambos ejercicios, la segunda (sección inferior) muestra la evolución de las probabilidades de pertenencia de estos datos a cada cluster así como la señal EMG y la cinemática grabadas durante el ejercicio, para poder apreciar como la probabilidad de pertenecer a los clusters que representan fatiga aumenta conforme aumenta la amplitud de la señal EMG y se reduce la amplitud en el movimiento realizado, que es nuestra medida de power output (ver sección 7.1). Se muestran estos resultados para los dos ejercicios (fatiga y no fatiga) concatenados, para poder apreciar mejor la progresión de los cambios. La separación entre ambos ejercicios está indicada por una línea negra continua vertical. Las figuras del ejercicio del bíceps contienen adicionalmente la distribución de los datos obtenidos para cada uno de los sujetos, para poder comprobar que siguen la misma distribución (tanto los datos del sujeto que participó en la sesión de entrenamiento como los datos del sujeto que no participó) que la distribución general mostrada en la figura 32.

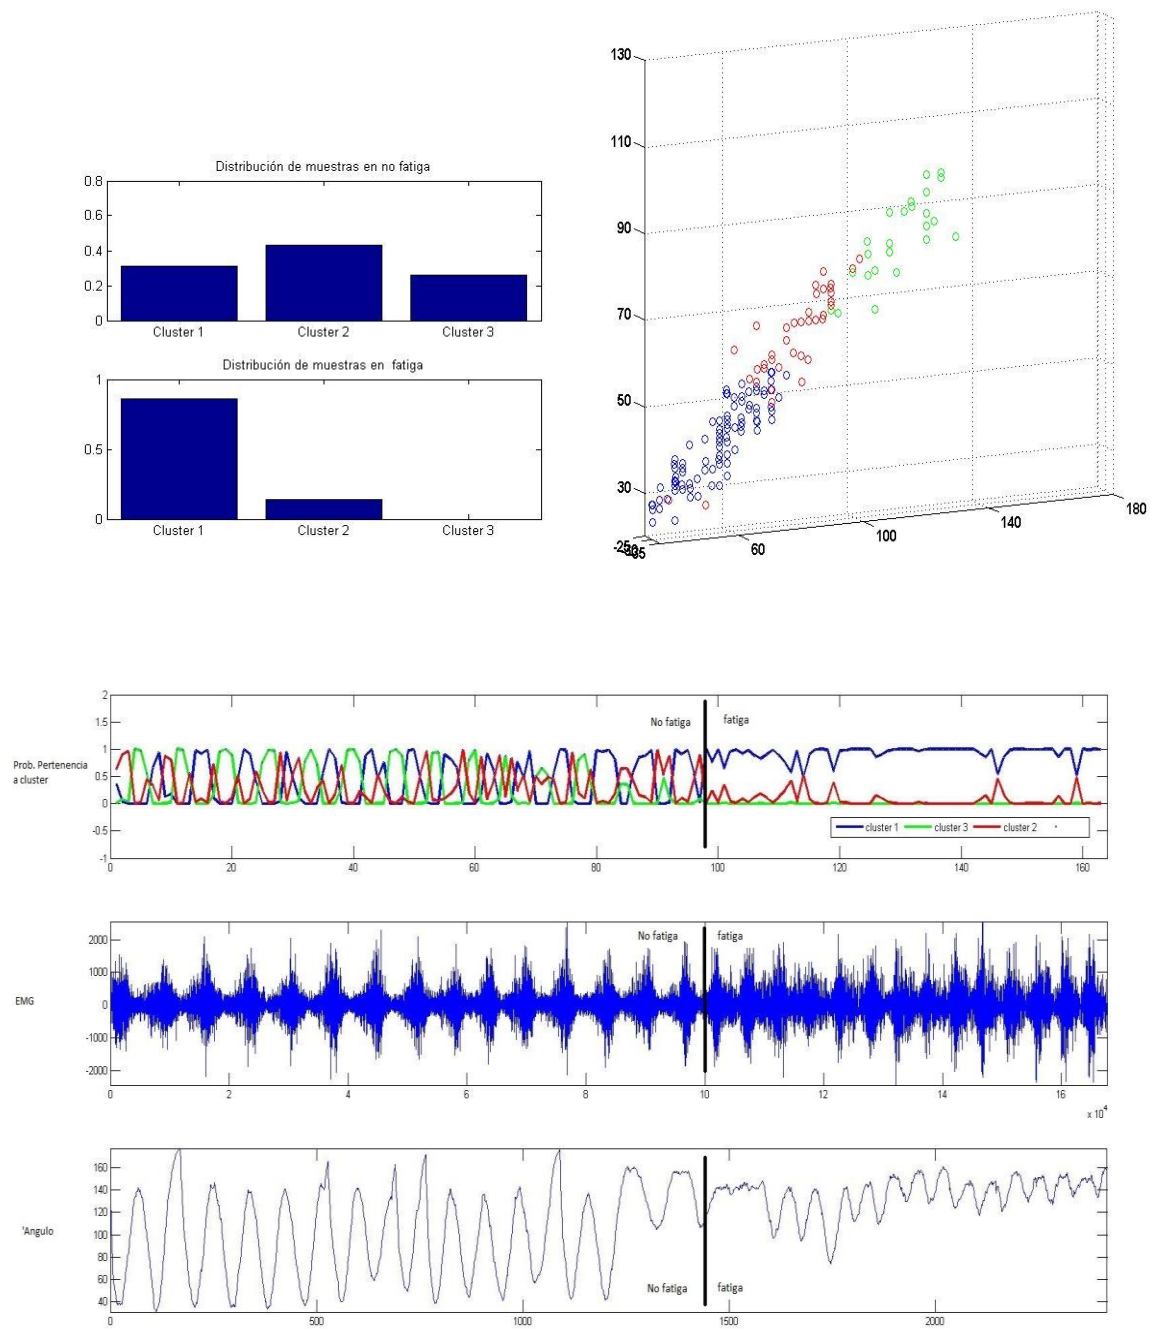


Figura 33. Resultados de clasificación para el Sujeto 3 en ejercicio Bíceps en no fatiga y fatiga. De mayor a menor fatiga los clusters son el 1, el 2 y el 3. Azul, rojo y verde respectivamente.

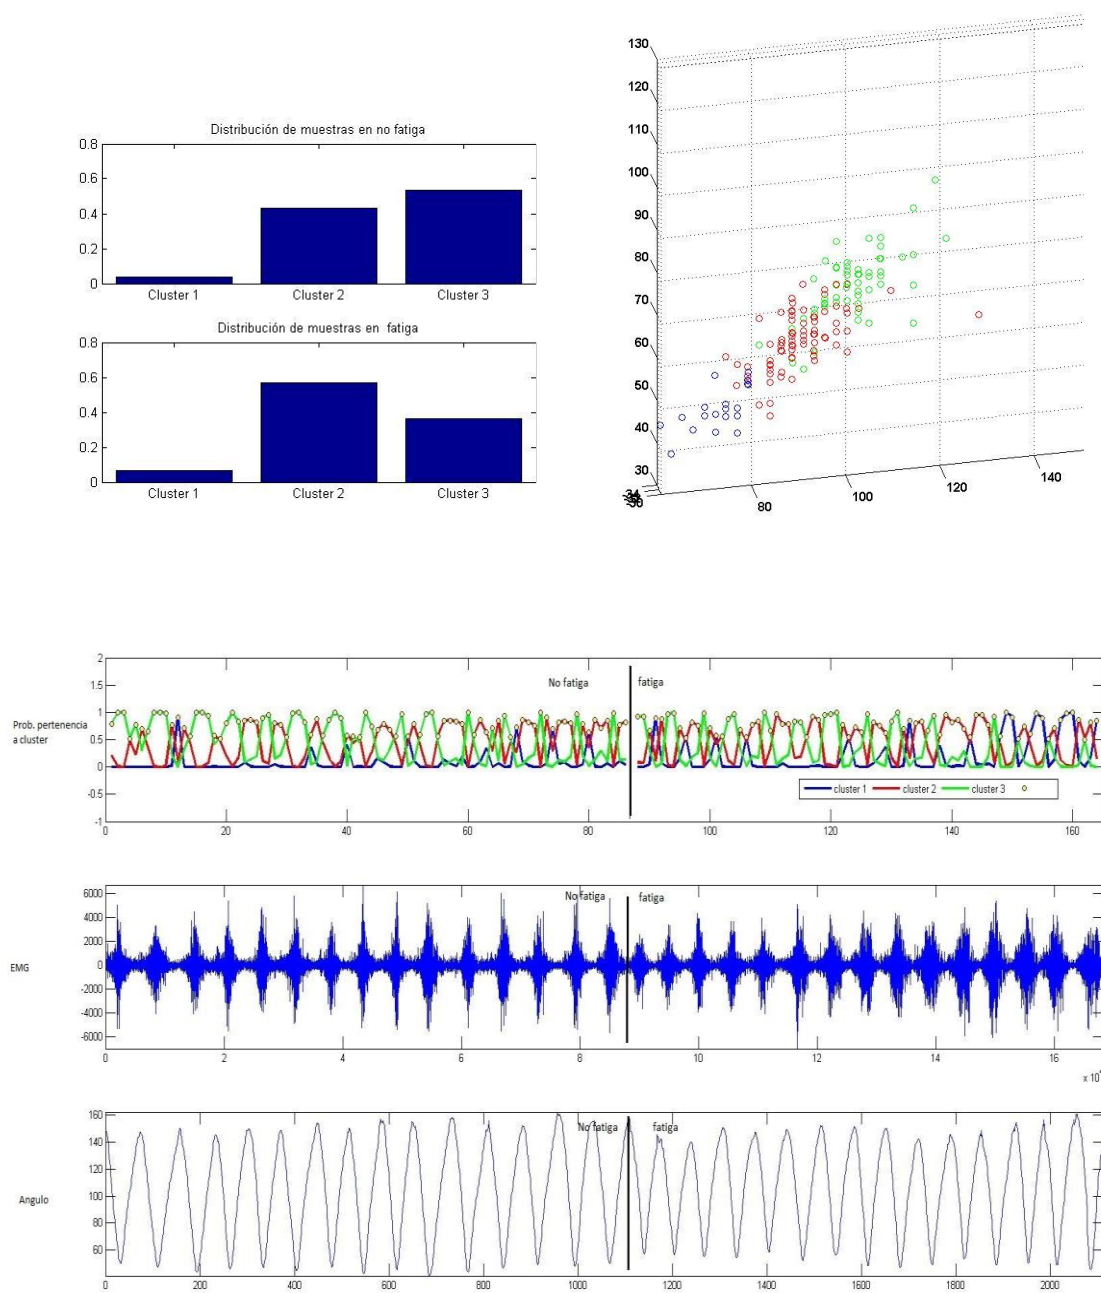


Figura 34. Resultados de clasificación para el Sujeto 6 en ejercicio Bíceps en no fatiga y fatiga. De mayor a menor fatiga los clusters son el 1, el 2 y el 3. Azul, rojo y verde respectivamente.

De estas figuras se extraen conclusiones muy interesantes. En primer lugar, de las distribuciones en tanto por 1 y la distribución gráfica de los datos, se puede observar que ambos sujetos siguen distribuciones similares, si bien el sujeto 6 no muestra un desplazamiento tan acusado como el sujeto 3 hacia los cluster de fatiga. Esto es consistente con lo mostrado en las gráficas de probabilidad de pertenencia a cada cluster, EMG y ángulo. Basta observar el EMG y ángulo de ambos sujetos para ver que mientras el sujeto 3 experimenta una fatiga mucho más acusada, reflejada en el aumento de la amplitud del EMG y la disminución de amplitud en el movimiento, el sujeto 6 experimenta una fatiga mucho más ligera, pues tanto el EMG como el ángulo se mantienen relativamente estables. Asimismo se observa que para el sujeto 3, en las repeticiones en fatiga el cluster 1 acapara prácticamente toda la probabilidad, mientras que para el sujeto 6 siguen estando bastante entremezcladas.

Esto se explica por la diferencia fisiológica (ver tabla 4) y de tonificación muscular entre ambos, que provocan que con un ejercicio similar, el sujeto 6 se fatigue mucho menos. Este resultado es importante, pues indica que el clasificador es capaz de adaptarse a sujetos de diferentes características, y seguir funcionando correctamente.

7.4 Modelo de músculo

En este apartado se muestran los resultados obtenidos para la estimación de par articular realizada por el modelo de Hill para el ejercicio de flexión de codo una vez ha sido calibrado para cada persona con una de las repeticiones de la sesión dinámica de no fatiga. Se analiza el modelo tanto en la sesión dinámica de no fatiga como en la sesión dinámica tras la fatiga dinámica en la que se trabaja bajo la suposición de que existe.

Para la validación del modelo la métrica usada en la medición del error en la estimación es el error cuadrático medio, definido por:

$$E_{rms} = \sqrt{\frac{1}{n} \sum_{k=1}^{k=n} (M_K - \widetilde{M}_k)^2} \quad (28)$$

Siendo n el número de muestras, M_K el par dado por la dinámica inversa con OpenSim, que es nuestro par de referencia, y \widetilde{M}_k el par estimado. También se ha usado el índice de correlación de Pearson (R) para estimar la correlación entre la estimación y el par referencia.

Los resultados normalizados en el tiempo de una de las repeticiones en la sesión de no fatiga para cada uno de los 5 sujetos se muestra en la figura 35. En ella se han dibujado el par obtenido por la dinámica inversa en azul y el par calculado por el modelo de Hill en línea discontinua roja. Se puede apreciar que la estimación es muy exacta en situaciones de no fatiga. También se ha indicado gráficamente en qué fase de flexión de codo se encuentra el sujeto a lo largo del tiempo normalizado. Los resultados de las métricas E_{rms} y R en media y desviación típica para cada uno de los sujetos (2,3,6,8,9) a lo largo de la sesión dinámica de condiciones de no fatiga se muestran en la tabla 5.




Figura 35. Comparación entre el torque estimado y el de referencia. Se muestra una estimación para una de las repeticiones de la sesión de flexión de codo en no fatiga para cada uno de los sujetos. La línea azul muestra el par obtenido con dinámica inversa, y en línea discontinua roja se dibuja el par obtenido con el modelo de Hill.

En la imagen se aprecia que el modelo se ajusta satisfactoriamente a lo largo del tiempo y en la tabla 5 se traduce en que la correlación es muy próxima a 1 para todos los sujetos y los errores son relativamente bajos.

Si con este mismo modelo calibrado para la sesión de fatiga se intenta estimar el par sin tener en cuenta el efecto de esta fatiga en el modelo se puede observar cómo en la figura 36 los errores en la estimación aumentan conforme aparece fatiga.

Este aumento también se observa en las métricas en la tabla 5 en las columnas de Modelo NF - Bíceps F.

	Modelo NF				Modelo F	
	Bíceps NF		Bíceps F		Bíceps F	
	R	ERMS	R	ERMS	R	ERMS
Sujeto 1	0.9473 ± 0.027	1.469 ± 0.319	0.879 ± 0.035	2.534 ± 0.437	0.887 ± 0.072	2.013 ± 0.35
Sujeto 2	0.9048 ± 0.07	3.1 ± 1.187	0.886 ± 0.059	4.25 ± 1.57	0.885 ± 0.057	3.712 ± 1.493
Sujeto 3	0.91 ± 0.25	1.689 ± 0.555	0.974 ± 0.012	1.899 ± 0.433	0.985 ± 0.009	1.618 ± 0.286
Sujeto 4	0.895 ± 0.038	1.581 ± 0.362	0.909 ± 0.031	2.138 ± 0.268	0.907 ± 0.0281	1.572 ± 0.443
Sujeto 5	0.906 ± 0.0449	2.028 ± 0.323	0.882 ± 0.097	2.389 ± 0.607	0.975 ± 0.057	1.851 ± 0.3743

Tabla 5. Media y desviación típica de las métricas de validación del modelo. Se ha analizado para cada sujeto los errores del modelo si no se tiene en cuenta el estado de fatiga (Modelo NF) frente a tener en cuenta el estado de fatiga (Modelo F).




Figura 36. Evolución del error cuadrático medio para una persona. El error aumenta para el ejercicio en fatiga (15 últimas repeticiones).

Al validar la propuesta de modificación de modelo, seguimos usando el modelo previamente calibrado para cada persona pero adaptándose en cada instante al nivel de fatiga que proporciona el detector conforme a lo expuesto en el capítulo 5. Los resultados de esta adaptación se muestran en la figura 37, donde el par de referencia se ha dibujado en azul, el modelo de Hill sin tener en cuenta la adaptación de fatiga en rojo, y el modelo integrado con el detector de fatiga en verde.

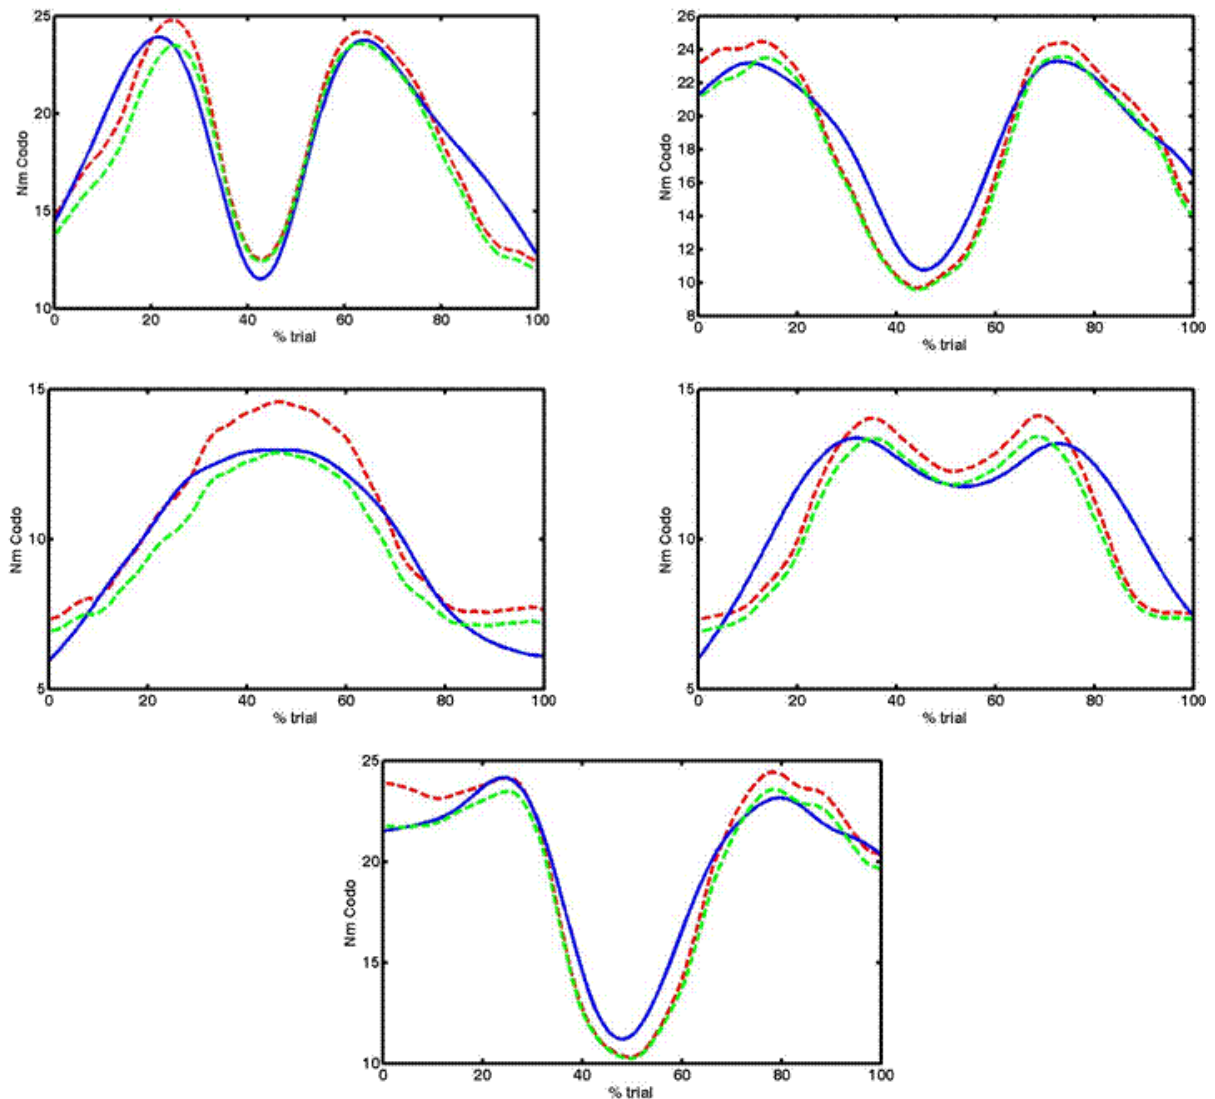


Figura 37. Comparación entre el torque estimado y el de referencia en la sesión de fatiga. Se muestra una estimación para una de las repeticiones de la sesión de flexión de codo en bajo fatiga para cada uno de los sujetos. La línea azul muestra el par obtenido con dinámica inversa, y en línea discontinua roja se dibuja el par obtenido con el modelo de Hill sin tener en cuenta el efecto de fatiga y en discontinua verde teniendo en cuenta en el modelo este efecto.

Las métricas en media y desviación típica de este modelo integrado se presentan en la tabla 5 en la columna de Modelo F- Bíceps F. S consigue una mejora pero no parece ser muy significativa, los niveles de correlación se mantienen para todas las personas y el error mejora pero mínimamente. Esto puede ser debido que se ha utilizado un modelo lineal de comportamiento frente a la fatiga muy sencillo (parámetro ω en el modelo de Hill), y que posiblemente existe una relación no lineal más compleja. Esto deberá ser estudiado en un trabajo futuro.

Capítulo 8

Conclusiones

En el transcurso de este proyecto se han estudiado diferentes indicadores de fatiga, obtenidos a partir de la señal EMG, para su uso en el desarrollo de un algoritmo de detección de fatiga muscular que aprenda, mediante técnicas de aprendizaje no supervisado, la distribución y tendencia que siguen estos indicadores con la aparición de la misma. De forma, se puede integrar en un modelo de estimación de fuerzas musculares, basado en el modelo de Hill, para permitir que el modelo se ajuste correctamente a situaciones de fatiga. También se han estudiado las sinergias musculares, una teoría cada vez más probada y aceptada, que establece que el sistema nervioso dispone de una "librería" de sub-tareas motoras (las sinergias) que puede combinar de forma flexible para generar cualquier movimiento, estas sinergias se obtienen a partir de la señal EMG mediante técnicas de reducción de dimensión.

Se han seleccionado para el estudio cinco indicadores de fatiga propuestos y usados por la literatura actual, la frecuencia media de la señal (MNF), la frecuencia mediana (Fmed), el índice espectral de Dimitrov (FI_{nsm5}), el valor cuadrático medio (RMS) y los cruces por cero (ZC). Adicionalmente también se ha estudiado si las sinergias se modifican en situaciones de fatiga y por tanto si se pueden usar en la detección de fatiga. De los seis indicadores estudiados, cinco han mostrado sufrir variaciones con la aparición de la fatiga, mostrando tendencias decrecientes la MNF, Fmed y ZC y crecientes el RMS y FI_{nsm5} . Sin embargo cuando se han relacionado estas variaciones con la capacidad de generación de fuerza del sujeto (que disminuye con la fatiga), sólo la MNF, Fmed, ZC y FI_{nsm5} han mostrado una correlación relevante, siendo MNF y ZC los más robustos. En cuanto a las sinergias, se ha visto que se mantienen bastante estables con la aparición de la fatiga, obteniendo unos grados de similaridad muy altos entre las sinergias obtenidas en fatiga y en no fatiga, y que por lo tanto no se pueden usar para la detección de fatiga.

Para el desarrollo del algoritmo de detección de fatiga se han usado los indicadores para los que se han obtenido mejores resultados, es decir MNF, Fmed, FI_{nsm5} y ZC. Se ha usado la técnica de *Gaussian Mixture Models* (GMM) para aprender la distribución que siguen estos datos con la aparición de la fatiga, obteniendo unas agrupaciones (clusters) coherentes, haciendo posible la identificación de estos clusters con los distintos niveles de fatiga. El algoritmo se ha validado con los datos de sujetos que participaron en el experimento del que se extrajeron los datos de entrenamiento y con los otros sujetos que no participaron. Estos datos de validación se obtuvieron de un experimento realizado un día distinto al de entrenamiento, lo que conlleva una disposición diferente de los electrodos (es imposible colocarlos siempre exactamente en la misma posición) y la variabilidad que esta disposición introduce en el EMG. Incluso con esta variación los resultados son favorables en ambos conjuntos de sujetos. Que el clasificador trabaje correctamente bajo esta situación implica que la distribución que siguen los datos en presencia de fatiga se mantiene entre sesiones. La validación con sujetos que no se han tenido en cuenta en el entrenamiento implica poder pensar que se puede desarrollar un algoritmo de detección de fatiga general para la población, pues aunque cada persona tenga un proceso de fatiga diferente, la distribución de los datos es similar y generalizable para detección del estado de fatiga o no fatiga muscular. Los estados de fatiga media y fatiga alta son más difusos y por tanto menos generalizables. Se ha visto que el algoritmo clasifica con mayor probabilidad las muestras como no fatiga al inicio del ejercicio, y que estas probabilidades van cambiando conforme aparece la fatiga. Sin embargo, la detección que se ha conseguido es de tres estados de fatiga (no fatiga, media y alta fatiga), pudiendo servir para hacerse una idea del nivel de fatiga, pero para el control de un modelo de forma continua es posible que se necesite entrenar el algoritmo de detección para cada sujeto.

Este trabajo ha servido para mostrar qué indicadores son más fiables en la detección de fatiga, y cómo pueden ser usados en el desarrollo de un algoritmo que sea capaz de establecer el nivel de fatiga de un sujeto automáticamente. Se ha mostrado que es posible integrar este algoritmo en un modelo muscular, de forma que se mejore su rendimiento en fatiga. También ha quedado demostrado que las sinergias no se pueden utilizar como un indicador de fatiga, pues no muestran una variación relevante en presencia de esta.

Este resultado nos lleva a reafirmar la idea de que las sinergias representan estrategias de movimiento a nivel neural y no a nivel muscular, que es donde se produce la fatiga.

El modelo de músculo se adapta satisfactoriamente con altos niveles de correlación para todos los sujetos de prueba bajo las condiciones de no fatiga. Se ha propuesto la modificación del modelo en función de la respuesta del clasificador de detección de fatiga y se han validado los resultados. Se ha producido una mejora en la estimación pero no parece muy significativa. Se hace necesario estudiar más en profundidad cómo se produce ese decremento de la generación de fuerza para conseguir resultados más relevantes en cuanto al modelado de músculo.

Es por ello que futuras líneas de trabajo a desarrollar incluyen la optimización del algoritmo de detección de fatiga para que se pueda usar en el control de un exoesqueleto en tiempo real, así como refinar la respuesta del modelo muscular a las condiciones de fatiga. Hasta el momento en la literatura sólo se han propuesto relaciones lineales para el modelado de disminución de la capacidad de la generación de fuerza en presencia de fatiga. Sería de interés estudiar otras relaciones fatiga-fuerza.

Capítulo9

Bibliografía

- [1] **Seyed A Safavynia, Gelsy Torres-Oviedo, and Lena H Ting.** "Muscle Synergies: Implications for Clinical Evaluation and Rehabilitation of Movement". Topics, vol. 17, no. 1, pp. 16-24, 2011.
- [2] **Clark DJ, Ting LH, Zajac FE, Neptune RR, Kautz SA.** "Merging of healthy motor modules predicts reduced locomotor performance and muscle coordination complexity post-stroke". J Neurophysiol. 2010;103(2):844-857.
- [3] **AB Ajiboye and RF Weir.** "Muscle synergies as a predictive framework for the EMG patterns of new hand postures". J Neural Eng. 2009 June ; 6(3): 036004
- [4] **Tresch MC, Cheung VCK, d'Avella A.** "Matrix factorization algorithms for the identification of muscle synergies: evaluation on simulated and experimental data sets". J. Neurophysiol. 2006; 95:2199–212. [PubMed: 16394079]
- [5] **Hyvarinen, A.; Karhunen, J.; Oja, E.** "Independent Component Analysis". Wiley; New York: 2001.
- [6] **Hyvarinen A, Oja E.** "Independent component analysis: algorithms and applications". Neural Networks. 2000; 13:411–30. [PubMed: 10946390]
- [7] **Lee DD, Seung HS.** "Learning the parts of objects by non-negative matrix factorization". Nature. 1999;401:788–91. [PubMed: 10548103]
- [8] **Lee, DD.; Seung, HS.** "Algorithms for non-negative matrix factorization". In: Leen, TK.; Dietterich, TG.; Tresp, V., editors. Advances in Neural Information Processing Systems. MIT Press; Cambridge, MA: 2001
- [9] **Nicolas A Turpin, Arnaud Guével, Sylvain Durand and François Hug.** "Fatigue-related adaptations in muscle coordination during a cyclic exercise in humans". J. Exp Biol vol. 214, pp. 3305-3314 October 1, 2011
- [10] **Gandevia, S. C.** "Spinal and Supraspinal Factors in Human Muscle Fatigue," Physiol. Rev., 81, pp. 1725–1789. 2001
- [11] **Cheng, A. J., and Rice, C. L.** "Fatigue and Recovery of Power and Isometric Torque Following Isotonic Knee Extensions". J. Appl. Physiol., 99, pp. 1446–1452. 2005
- [12] **Westerblad, H., and Allen, D. G.** "Recent Advances in the Understanding of Skeletal Muscle Fatigue". Curr. Opin. Rheumatol., 14, pp. 648–652. 2002
- [13] **Karlsson S, Yu J, Akay M.** "Enhancement of spectral-analysis of myoelectric signals during static contractions using wavelet methods". IEEE Trans Biomed Eng; vol. 46 pp. 670–684.

- [14] **Karlsson S, Yu J, Akay M.** "Time-frequency analysis of myoelectric signals during dynamic contractions: a comparative study". IEEE Trans Biomed Eng 2000;47:228–38.
- [15] **Shankar S, Gander RE, Brandell BR.** "Changes in the myoelectric signal (MES) power spectra during dynamic contractions". Electroencephalography and Clinical Neurophysiol;73(2):142–50. 1989
- [16] **M. González-Izal , A. Malanda I. Navarro-Amézqueta , E.M. Gorostiaga , F. Mallor ,J. Ibañez , M. Izquierdo.** "EMG spectral indices and muscle power fatigue during dynamic contractions". Journal of Electromyography and Kinesiology, vol.20, issue 2, pp. 233-240, April 2010
- [17] **Panagiotis K.Artemiadis and Kostas J.Kyriakopoulos.** "Assessment of muscle fatigue using a probabilistic framework for an EMG-based robot control scenario". BioInformatics and BioEngineering, 2008.BIBE 2008. 8th IEEE International Conference on
- [18] <http://www.seniam.org/>
- [19] **Andrea d’Avella, Pjilippe Saltiel and Emilio Bizzi.** "Combinations of muscle synergies in the construction of a natural motor behavior". Natura Neuroscience vol.6, pp 300-308 ,2003
- [20] **Stefan Karlsson, Björn Gerdle.** " Mean frequency and signal amplitude of the surface EMG of the quadriceps muscles increase with increasing torque — a study using the continuous wavelet transform". Journal of Electromyography and Kinesiology, vol.11, pp. 131–140 2001
- [21] **Guillaume Rao, Eric Berton, David Amarantini, Laurent Vigouroux and Thomas S. Buchanan.** "An EMG-Driven Biomechanical Model That Accounts for the Decrease in Moment Generation Capacity During a Dynamic Fatigued Condition". JBiomechEng 132(7), May 14, 2010
- [22] **Pasamontes García;Mario.** "La transformada Wavelet en el análisis de señales: aplicación a vibraciones en sistemas rotativos". Leganés, 2005. Proyecto final de carrera presentado en la Escuela Politécnica Superior de la Universidad Carlos III de Madrid. 192 p.
- [23] **Roberto Merletti, Philip A.Parker.** "Electromyography, Physiology, Engineering, and Noninvasive Applications". IEE Press Series in Biomedical Engineering. 2004
- [24] **Daniel Ramos Gutiérrez.** "Estudio cinemático del cuerpo humano mediante Kinect". Proyecto final de carrera presentado en la Universidad Politécnica de Madrid 2013.
- [25] **S. L. Delp, F. C. Anderson, A. S. Arnold, P. Loan, A. Habib, C. T .John, E. Guendelman, D. G. Thelen.** "OpenSim: open-sorce software to create and analyze dynamic Simulations of movement". IEEE Transactions on Biomedical Engineering, 2007, vol. 55, pp. 1940-1950.
- [26] **Holzbaaur K R, Murray W M, Delp S L.** "A model of upper extremity for simulating musculoskeletal surgery and analyzing neuromuscular control". Ann Biomed Eng. 2005 Jun; 33(6): 829-40.
- [27] **A. V. Hill,** "The heat of shortening and the dynamic constants of muscle," Proc. R. Soc. Lond. Biol., vol. 126, pp. 136–195, 1938.
- [28] **D R. Bueno, L. Montano.** "An Optimized Model for Estimation of Muscle Contribution and Human Joint Torques from sEMG Information" IEEE Eng. Med. Biol. 2012. Aug., San Diego.

- [29] **T.S. Buchanan, D.G. Lloyd, K. Manal, T.F. Besier.** “Neuromusculoskeletal Modeling: Estimation of Muscle Forces and Joint Moments and Movements From Measurements of Neural Command”. *J ApplBiomech.* 2004 November; 20(4):367-395.
- [30] <http://www.car.upm-csic.es/bioingenieria/hyper/index.htm>
- [31] <http://www.mathworks.com/matlabcentral/fileexchange/26184-em-algorithm-for-gaussian-mixture-model>

Anexo I

Músculos medidos




Figura 38. Deltoides Anterior, Lateral y Posterior. El deltoides lateral no se aprecia completamente en la foto porque se encuentra en el lateral del brazo, entre el anterior y el posterior.




Figura 39. Brachioradialis




Figura 40. Bíceps Brachii




Figura 41. Tríceps Long, Lateral y Medial.




Figura 42. Flexor CarpiRadialis




Figura 43. Extensor Digitorum




Figura 44. Flexor Carpi Ulnaris(Resaltado en negrita)




Figura 45. Infraspinatus




Figura 46. PectoralisMajor

Anexo II

OpenSim

Open es una potente herramienta, disponible de forma gratuita, para modelar y simular movimiento. Ofrece la posibilidad de crear modelos musculares, y poder visualizarlos en tres dimensiones (figura 47)




Figura 47. Pantalla principal de OpenSim. OpenSim ofrece la posibilidad de rotar el modelo 3D para observarlo desde diferentes ángulos.

Una vez creado el modelo, se pueden cargar movimientos para visualizar como los realiza el modelo, y por tanto poder comprobar que el movimiento es el esperado. Estos movimientos se definen por ficheros específicos ".mot" que contienen el ángulo en cada instante temporal para las articulaciones que intervienen en el movimiento. Una vez cargado el movimiento OpenSim permite el cálculo de diferentes características musculares durante la realización del mismo, para este trabajo se han las longitudes de músculo y los brazos de momento.

Asimismo permite obtener la cinética del movimiento, calculada mediante dinámica inversa y visualizarla (figura 48). Mediante esta herramienta de la dinámica inversa es como se han calculado las medidas de referencia usadas para calibrar y validar el modelo muscular.

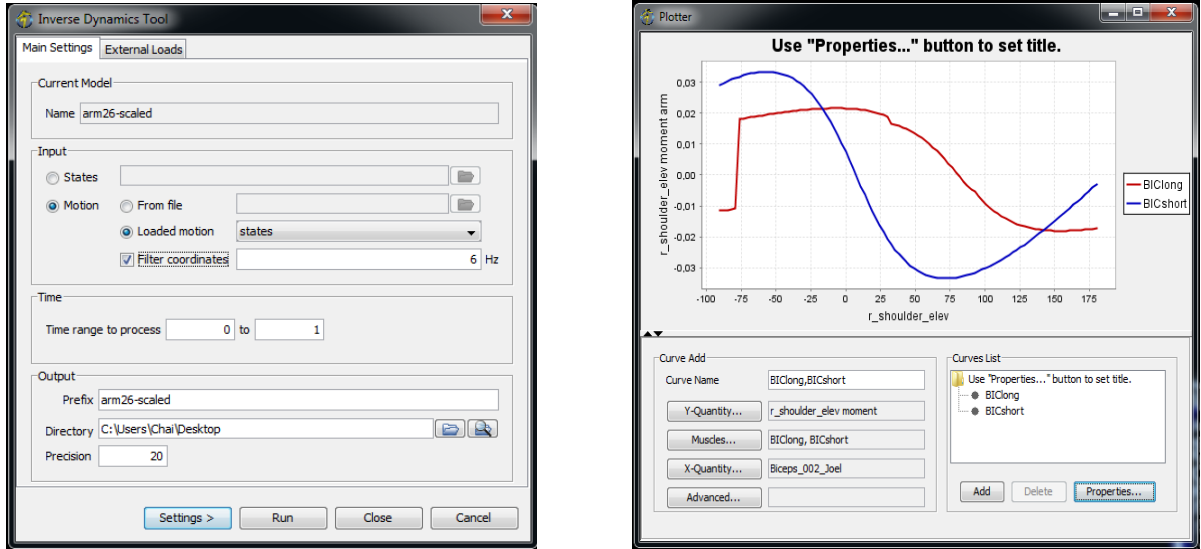


Figura 48. Generación de dinámica inversa OpenSim. A la izquierda la herramienta de cálculo de dinámica inversa, y a la derecha la visualización de la cinética generada.

Dada la cinemática y las cargas externas de un movimiento, la dinámica inversa permite calcular la fuerza neta y el momento de cada articulación que interviene en dicho movimiento a través de las ecuaciones mecánicas de movimiento:

$$M(q)\ddot{q} + C(q, \dot{q}) + G(q) = \tau$$

donde q, \dot{q}, \ddot{q} son los vectores de posición, velocidad y aceleración respectivamente. $M(q) \in R^{N \times N}$ es la matriz de masas del sistema, $C(q, \dot{q}) \in R^N$ es el vector de las fuerzas centrífuga y de Coriolis, $G(q) \in R^N$ es el vector de fuerzas gravitacionales y $\tau \in R^N$ es el vector de fuerzas genéricas.

Anexo III

Resultados adicionales

Indicadores de fatiga

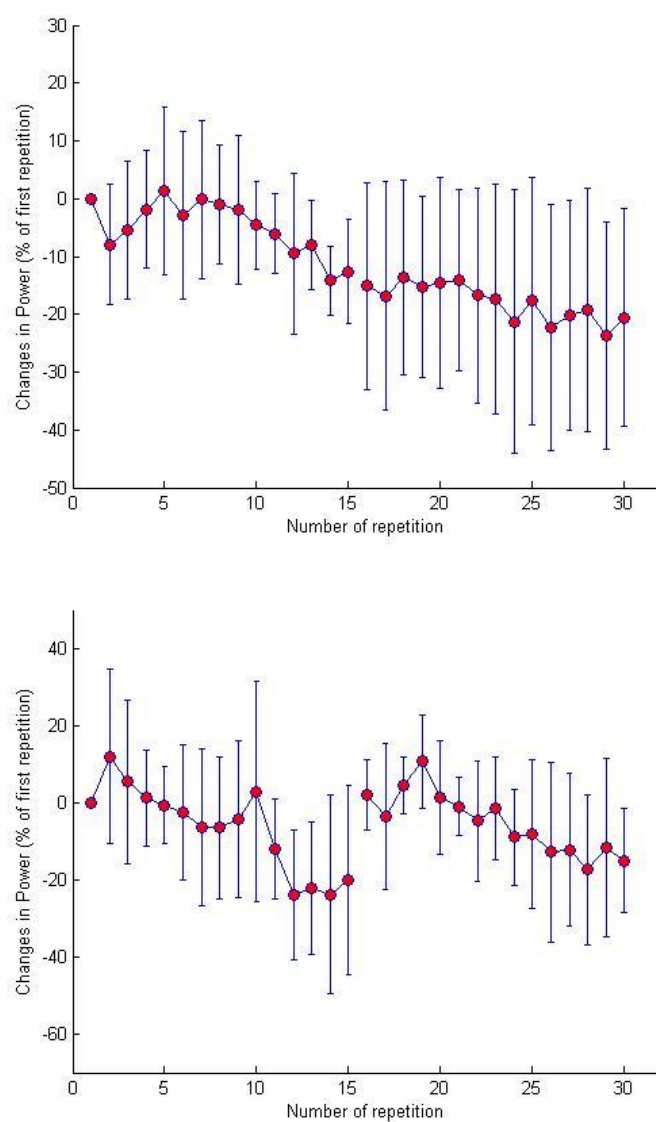


Figura 49. Evolución del Power Output. De arriba a abajo, ejercicio de Deltoides y de Tríceps. Se muestran las 30 repeticiones realizadas (15 en no fatiga y 15 en fatiga) como porcentaje de cambio desde la primera repetición.

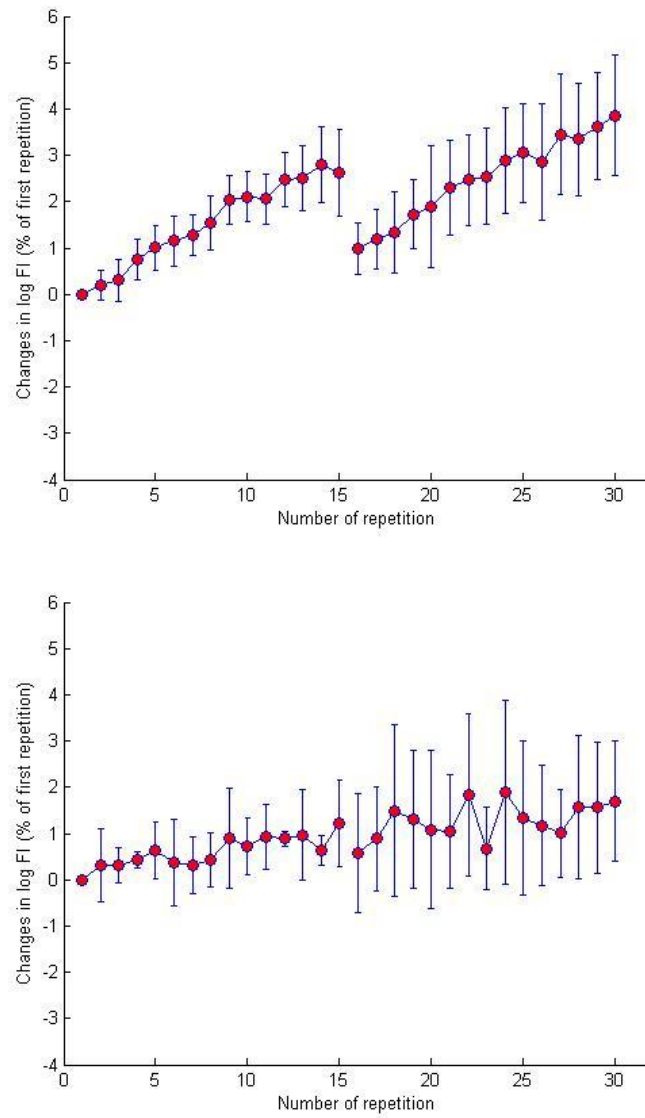


Figura 50. Evolución del log FI (Se toma el logaritmo para que siga una distribución normal [16]). De arriba a abajo, de Deltoides y de Tríceps. Se muestran las 30 repeticiones realizadas (15 en no fatiga y 15 en fatiga) como porcentaje de cambio desde la primera repetición.

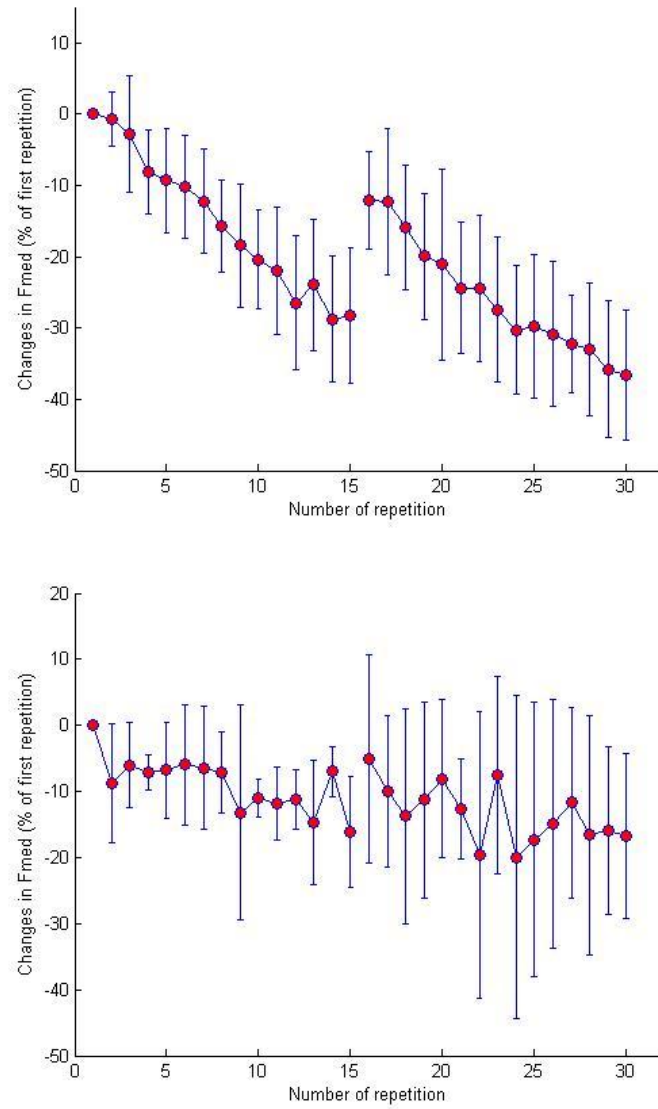


Figura 51. Evolución de la frecuencia mediana (Fmed). De arriba a abajo, ejercicio de Deltoides y de Tríceps. Se muestran las 30 repeticiones realizadas (15 en no fatiga y 15 en fatiga) como porcentaje de cambio desde la primera repetición.

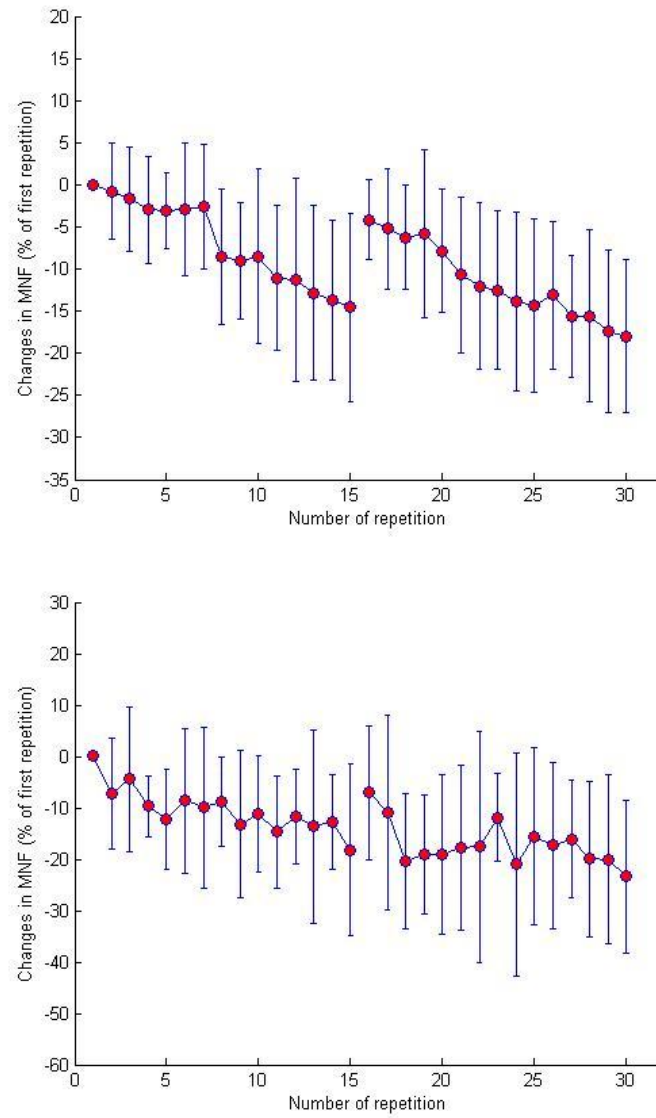


Figura 52. Evolución de la frecuencia media (MNf). De arriba a abajo, ejercicio de Deltoides y de Tríceps. Se muestran las 30 repeticiones realizadas (15 en no fatiga y 15 en fatiga) como porcentaje de cambio desde la primera repetición.

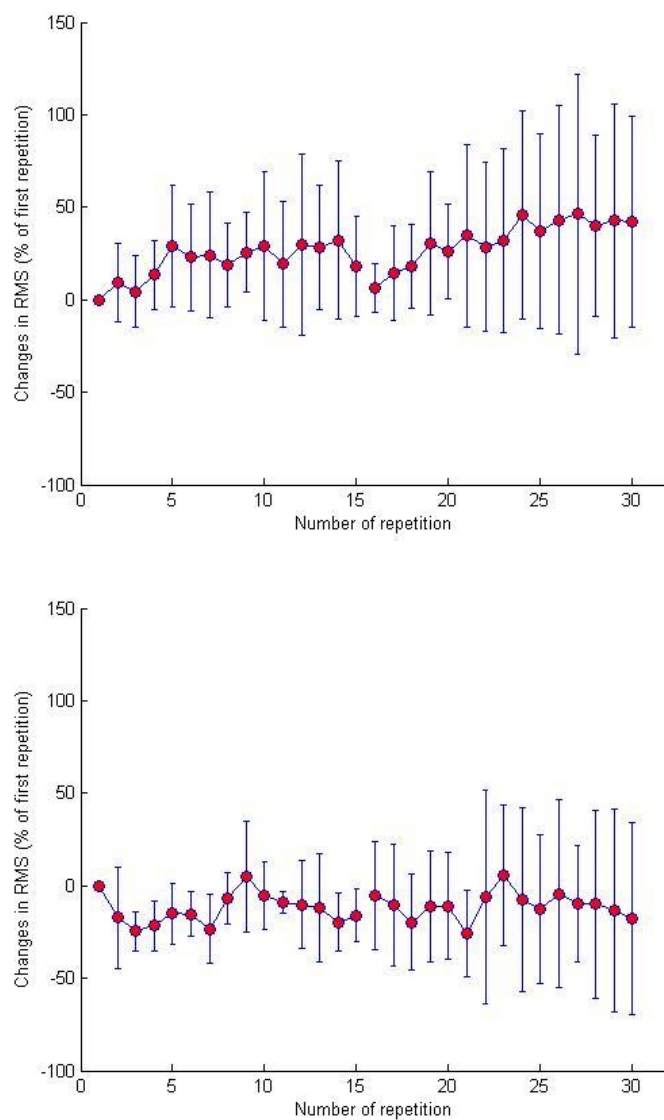


Figura 53. Evolución del RMS. De arriba a abajo, ejercicio de Bíceps, de Deltoides y de Tríceps. Se muestran las 30 repeticiones realizadas (15 en no fatiga y 15 en fatiga) como porcentaje de cambio desde la primera repetición.

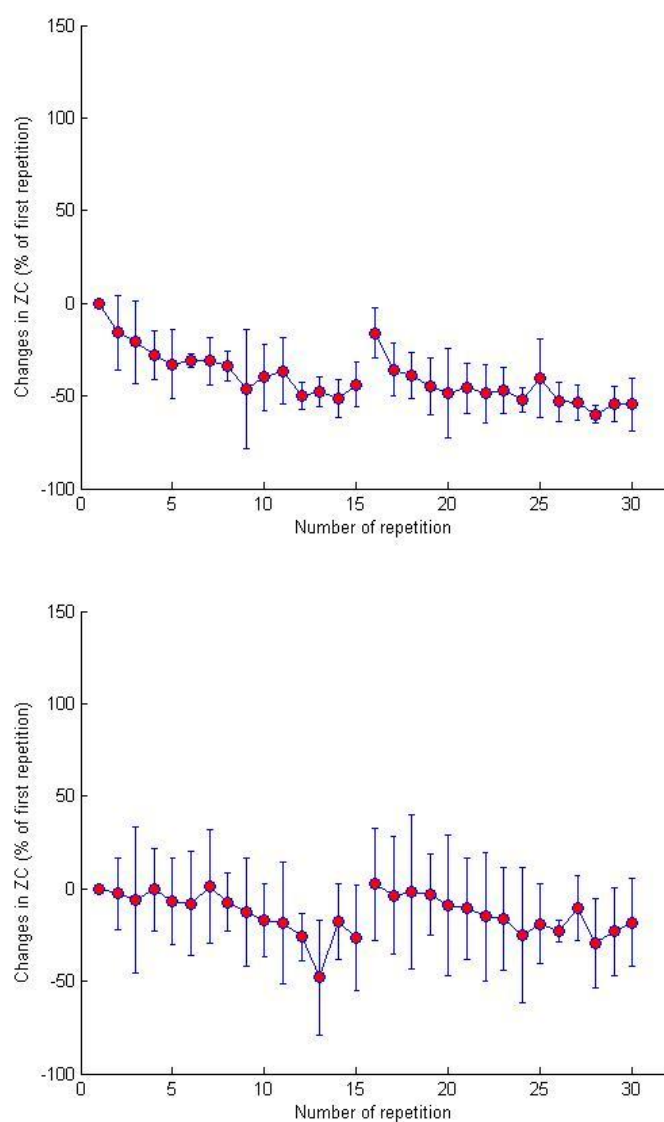


Figura 54. Evolución del zerocrossing (ZC). De arriba a abajo, ejercicio de Bíceps, de Deltoides y de Tríceps. Se muestran las 30 repeticiones

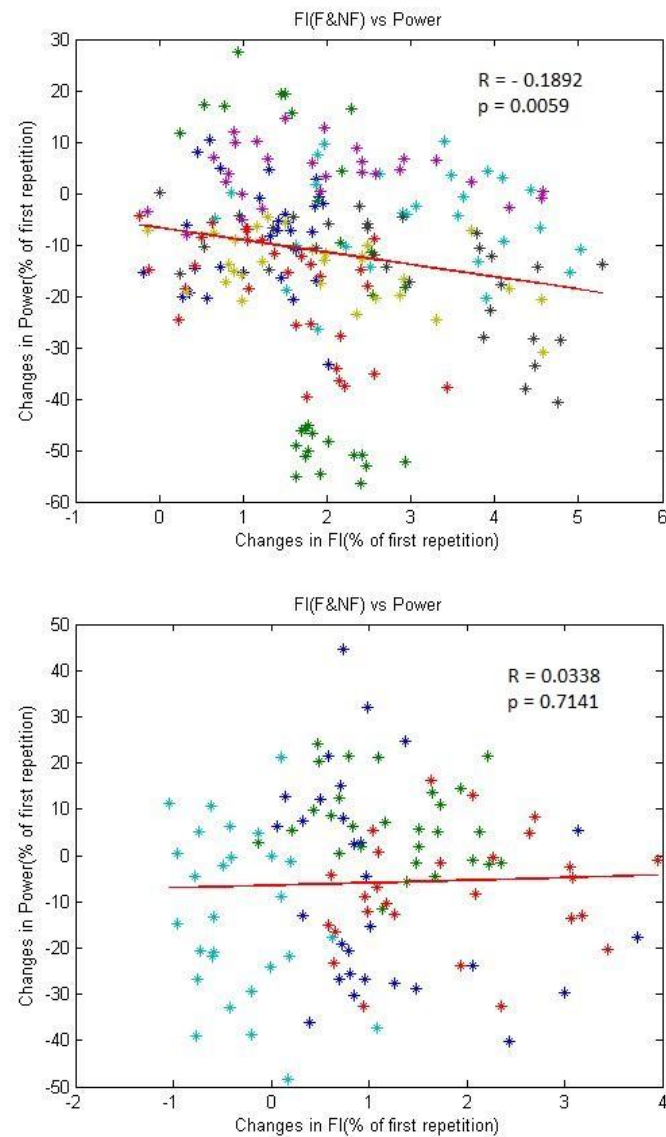


Figura 55. Distribución del log FI respecto del PowerOutput (% de la primera repetición). De arriba a abajo, ejercicio de Deltoides y de Tríceps. R, coef. correlación Pearson y p el p-valor.

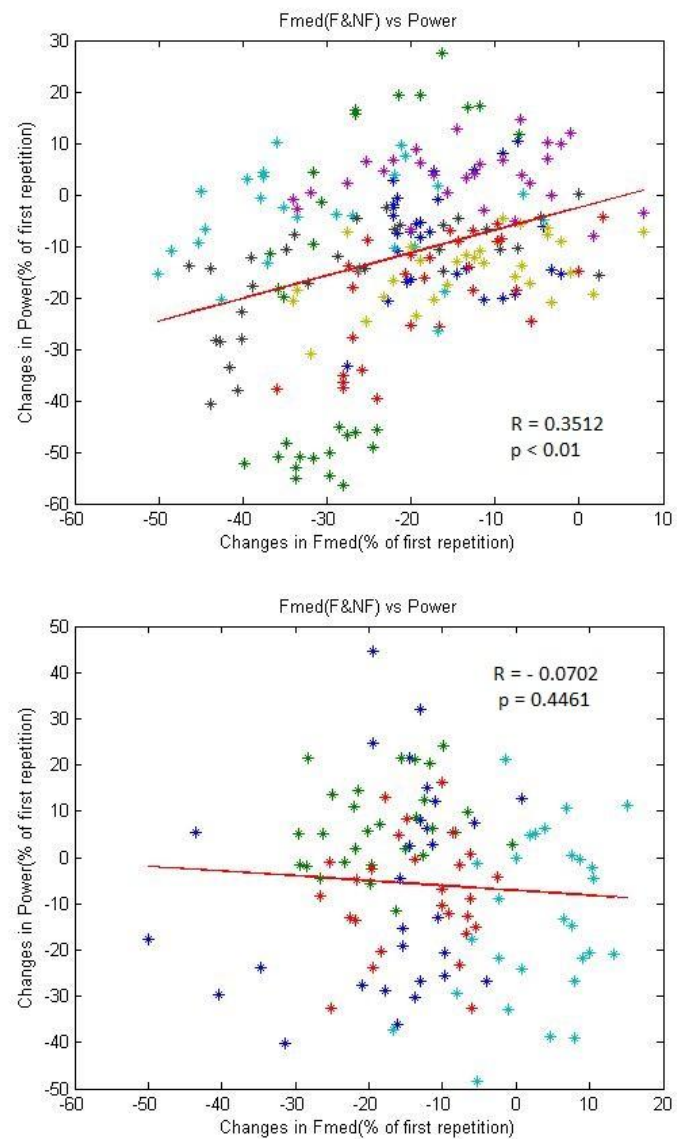


Figura 56. Distribución de Fmed respecto del PowerOutput (% de la primera repetición). De arriba a abajo, ejercicio de Deltoides y de Tríceps. R, coef. correlación Pearson y p el p-valor.

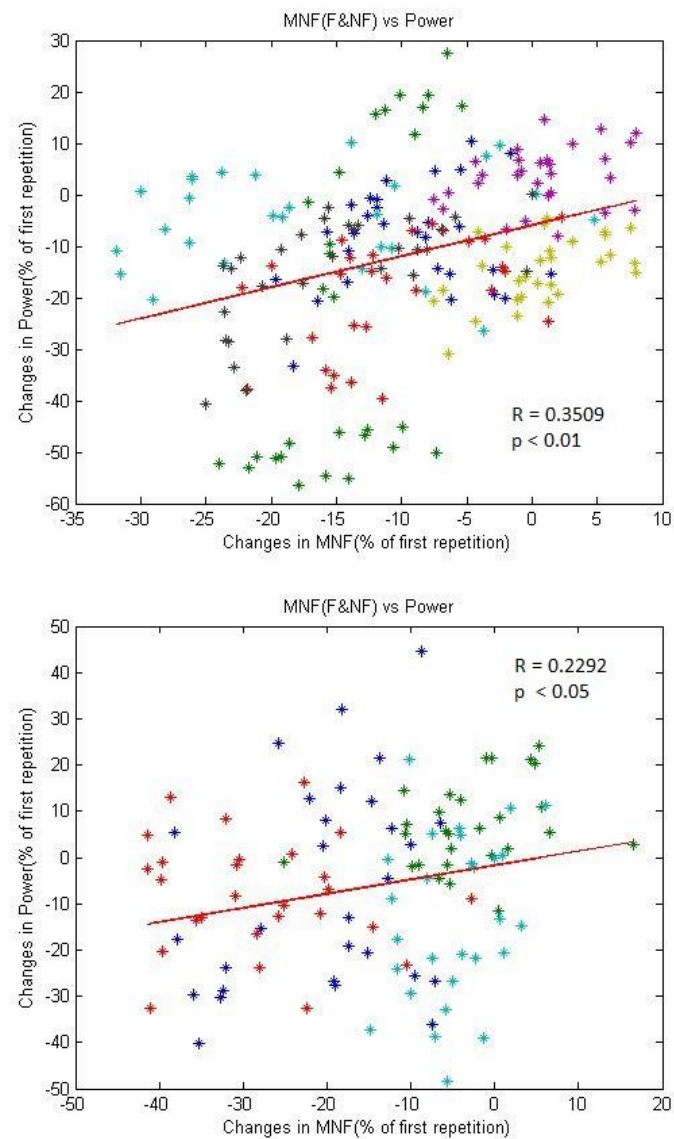


Figura 57. Distribución de MNF respecto del Power Output (% de la primera repetición). De arriba a abajo ejercicio de Deltoides y de Triceps. R, coef. correlación Pearson y p el p-valor.

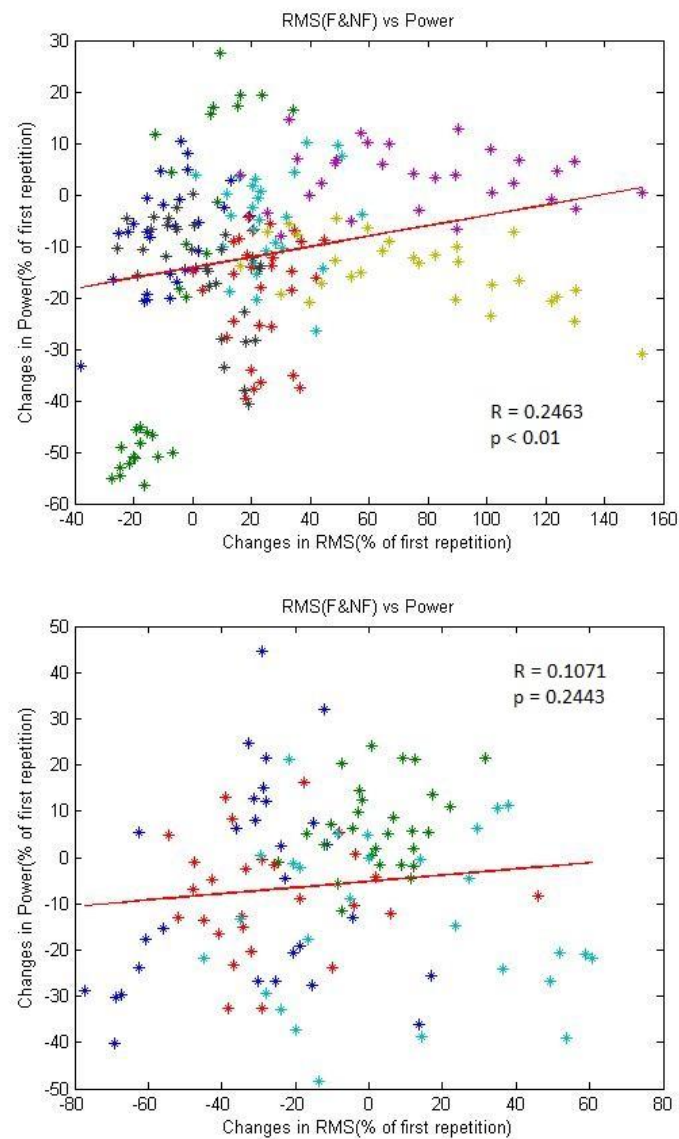


Figura 58. Distribución de RMS respecto del Power Output (% de la primera repetición). De arriba a abajo ejercicio de Deltoides y de Triceps. R, coef. correlación Pearson y p el p-valor.

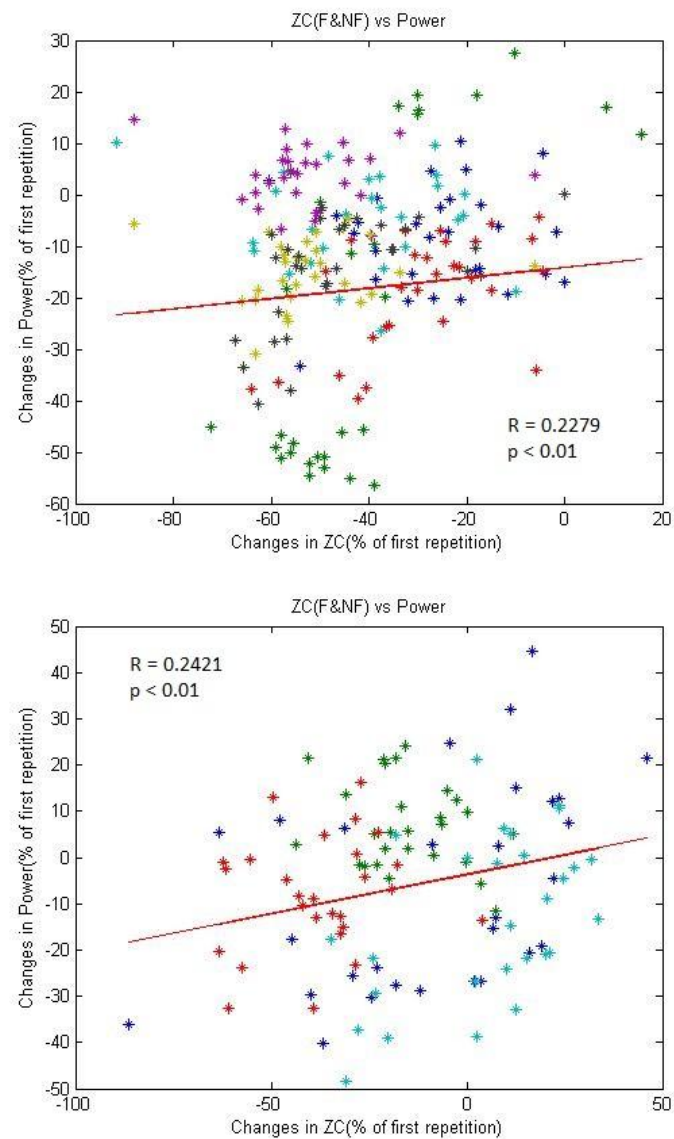


Figura 59. Distribución de ZC respecto del Power Output (% de la primera repetición). De arriba a abajo ejercicio de Deltoides y de Tríceps. R, coef. correlación Pearson y p el p-valor.

Sinergias




Figura 60. Evolución de la varianza explicada para el ejercicio del Tríceps (No fatiga izquierda y fatiga derecha). El resultado se muestra en media \pm desviación estándar para todos los sujetos.

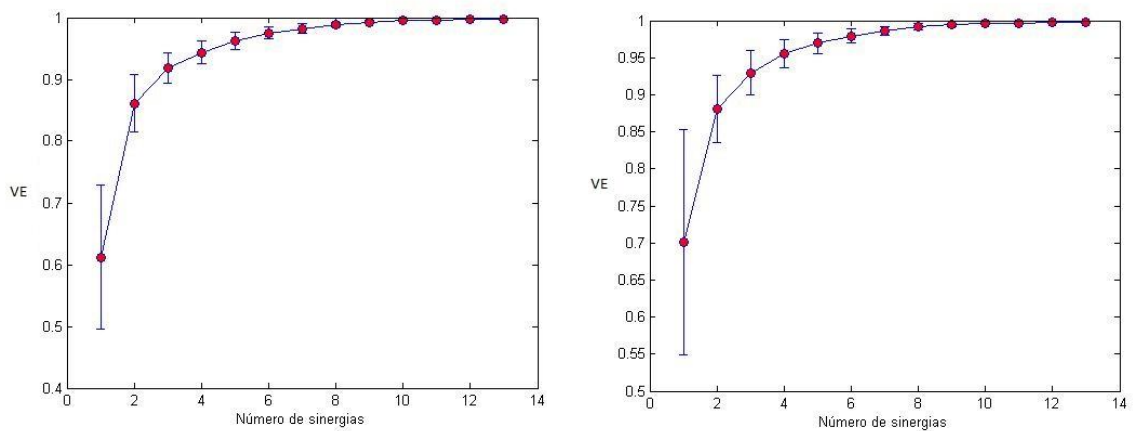


Figura 61. Evolución de la varianza explicada para el ejercicio del Hombro (No fatiga izquierda y fatiga derecha). El resultado se muestra en media \pm desviación estándar para todos los sujetos.

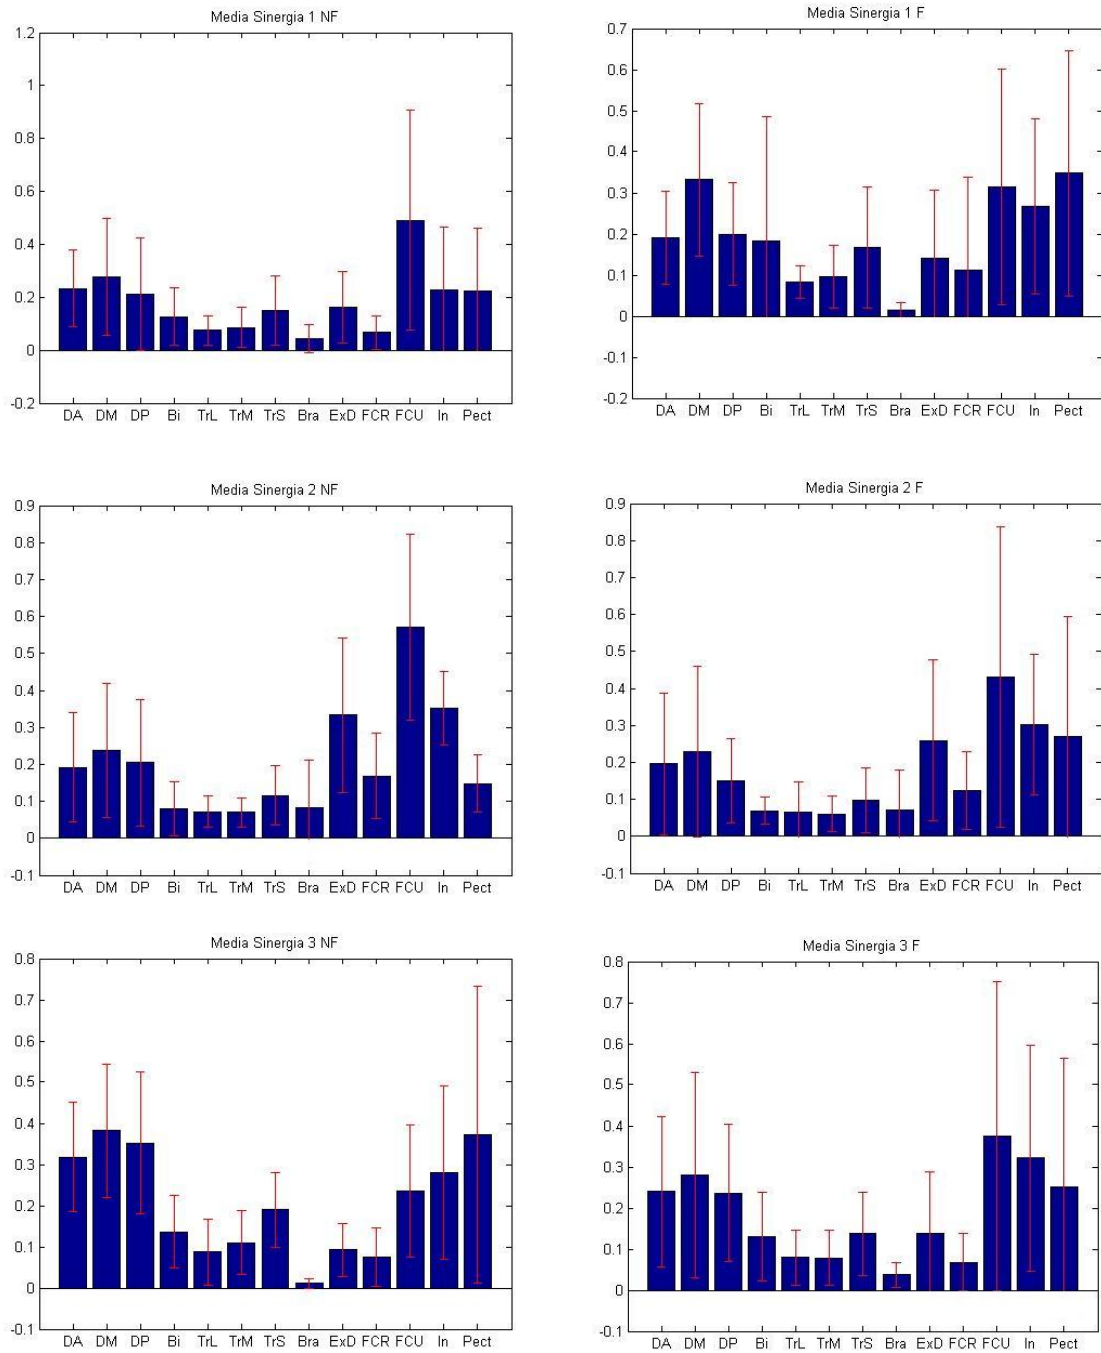


Figura 62. Sinergias obtenidas para el ejercicio del Hombro. En condición de no fatiga (Izquierda) , y en condición de fatiga (Derecha)

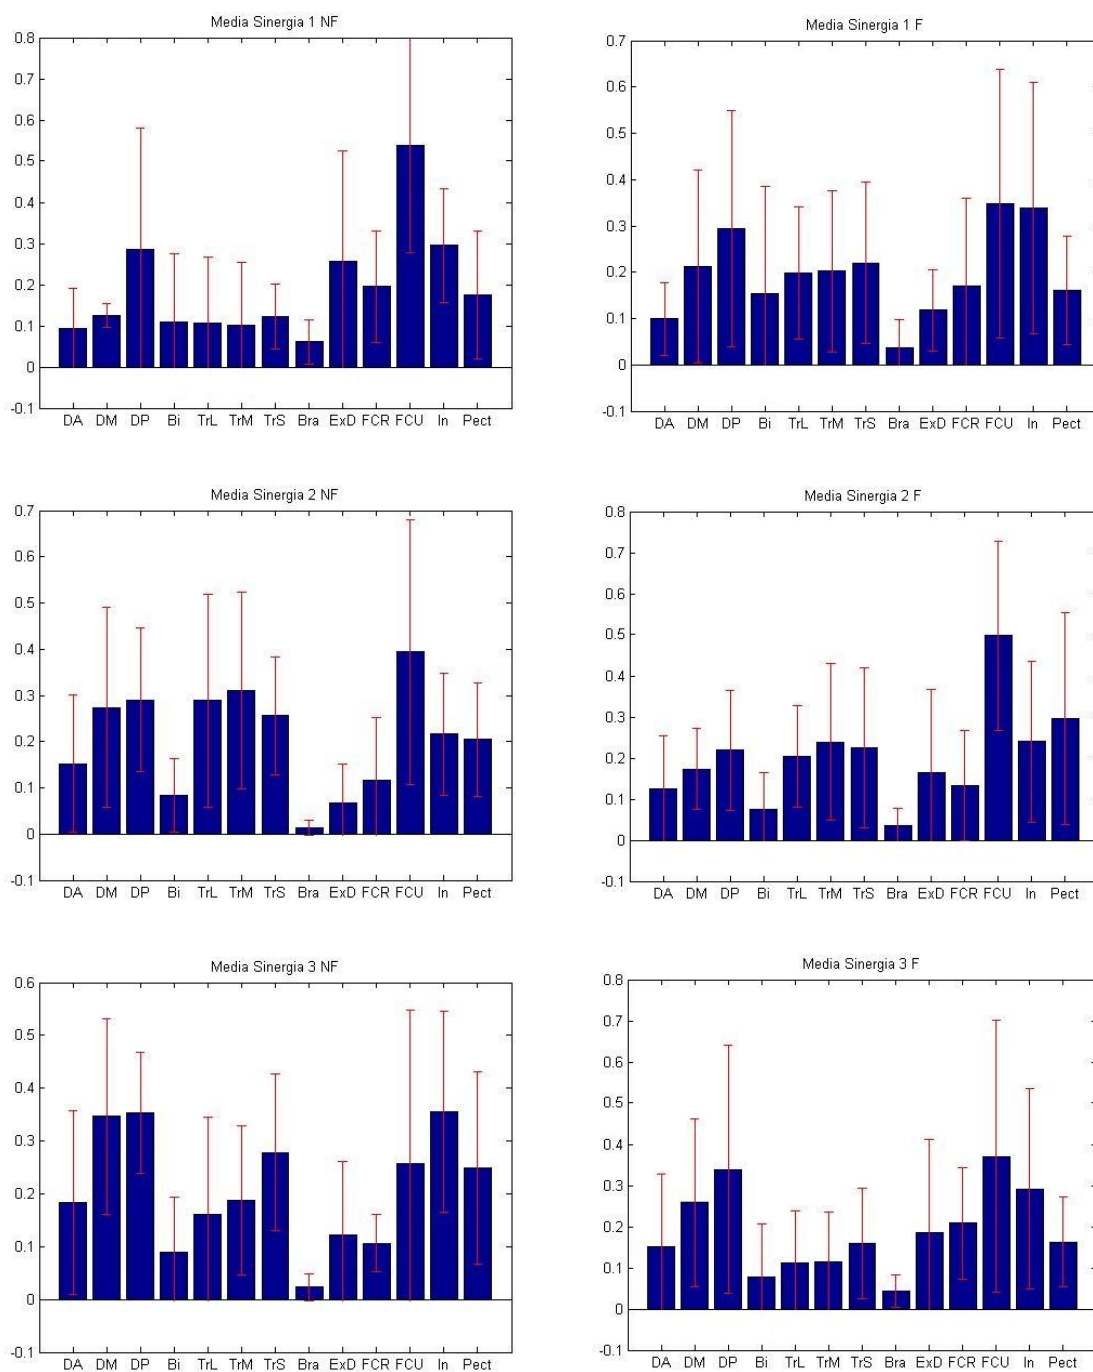


Figura 63. Sinergias obtenidas para el ejercicio del Tríceps. En condición de no fatiga (Izquierda) , y en condición de fatiga (Derecha)

Algoritmo de detección de fatiga

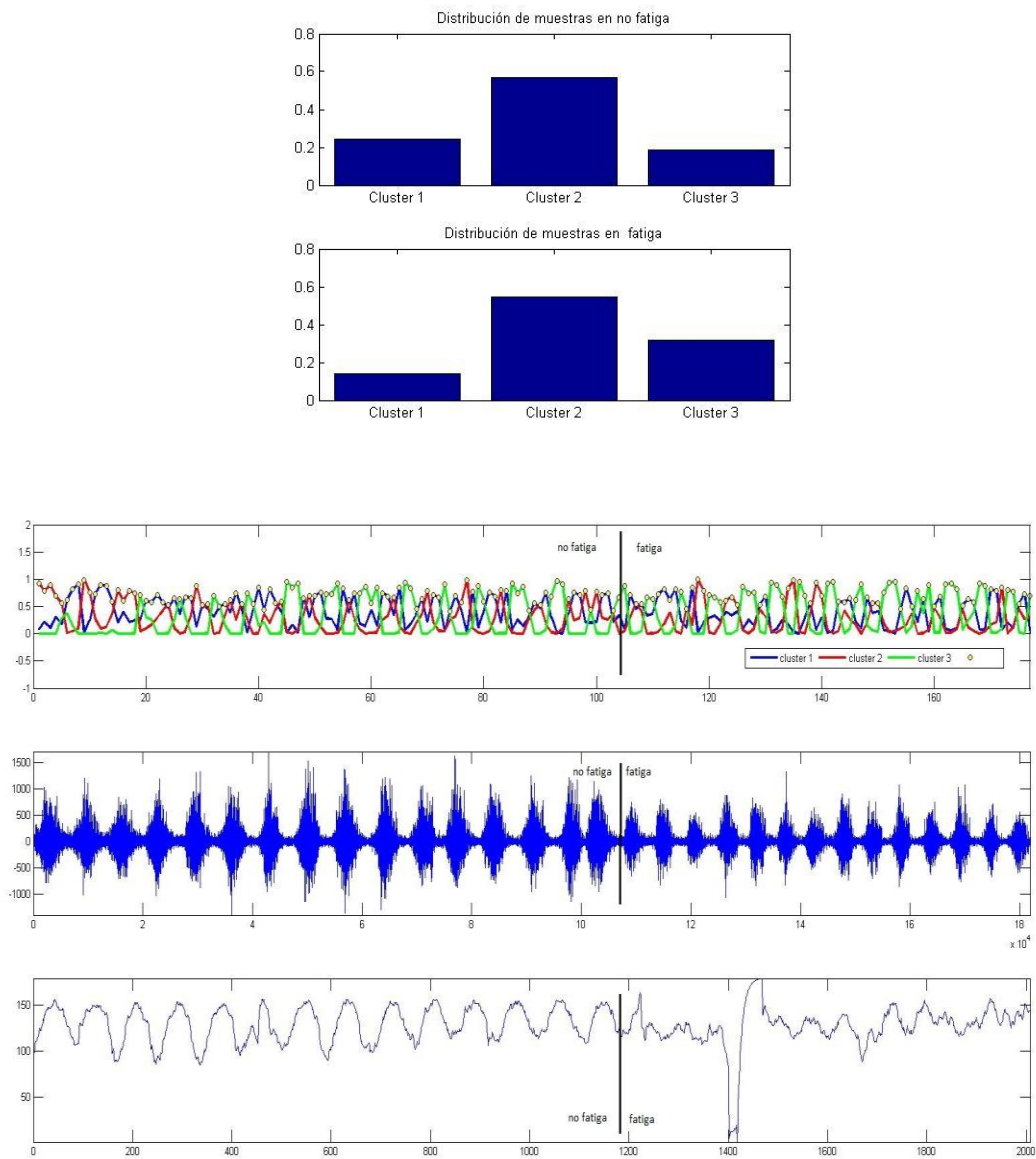


Figura 64. Resultados de clasificación para el Sujeto 3 en ejercicio Tríceps en no fatiga y fatiga. De mayor a menor fatiga los clusters son el 3, el 1 y el 2. Verde, azul y rojo respectivamente.

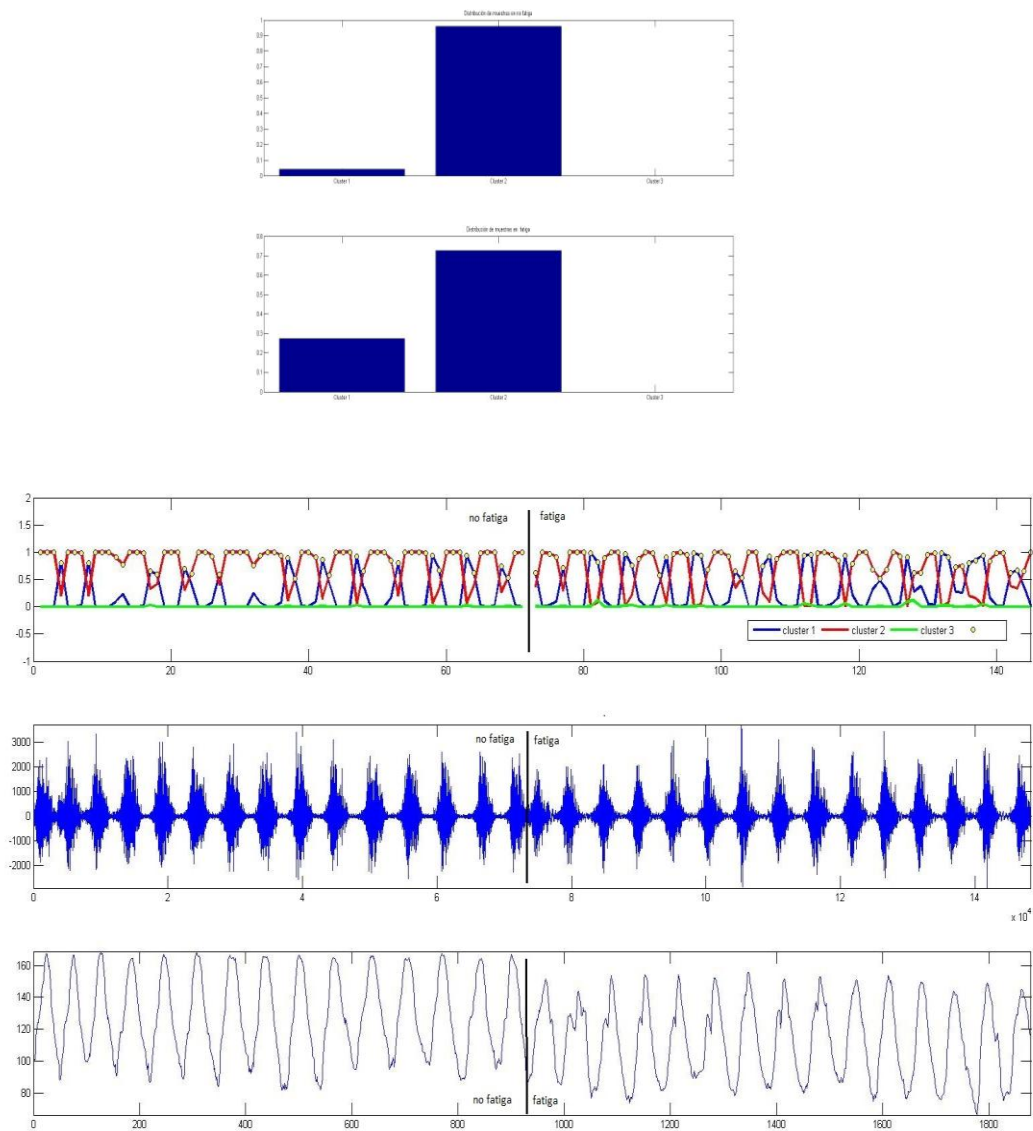


Figura 65. Resultados de clasificación para el Sujeto 6 en ejercicio Tríceps en no fatiga y fatiga. De mayor a menor fatiga los clusters son el 3, el 1 y el 2. Verde, azul y rojo respectivamente.

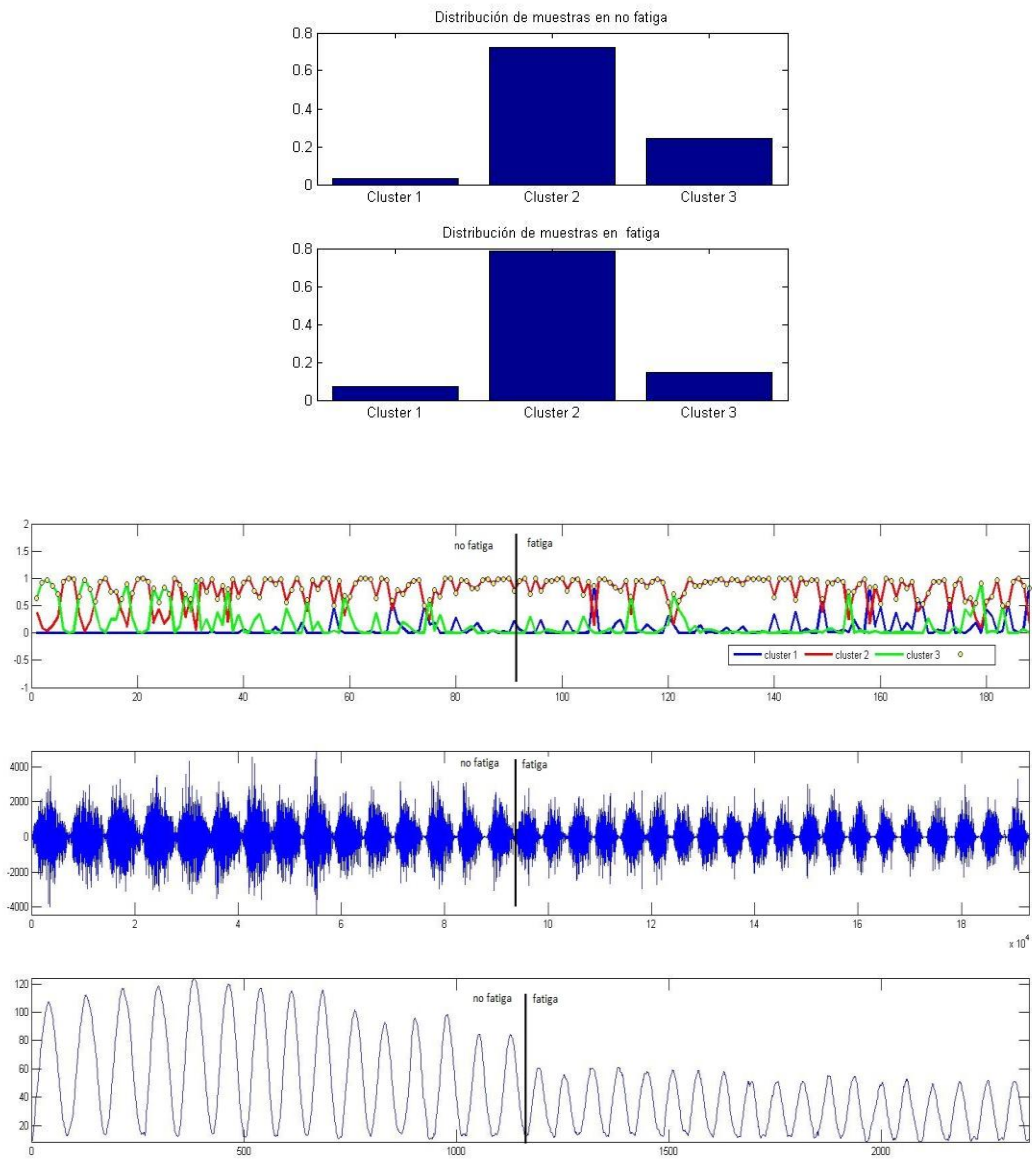


Figura 66. Resultados de clasificación para el Sujeto 3 en ejercicio de Hombro en no fatiga y fatiga.
De mayor a menor fatiga los clusters son el 1, el 2 y el 3. Azul, rojo y verde respectivamente.

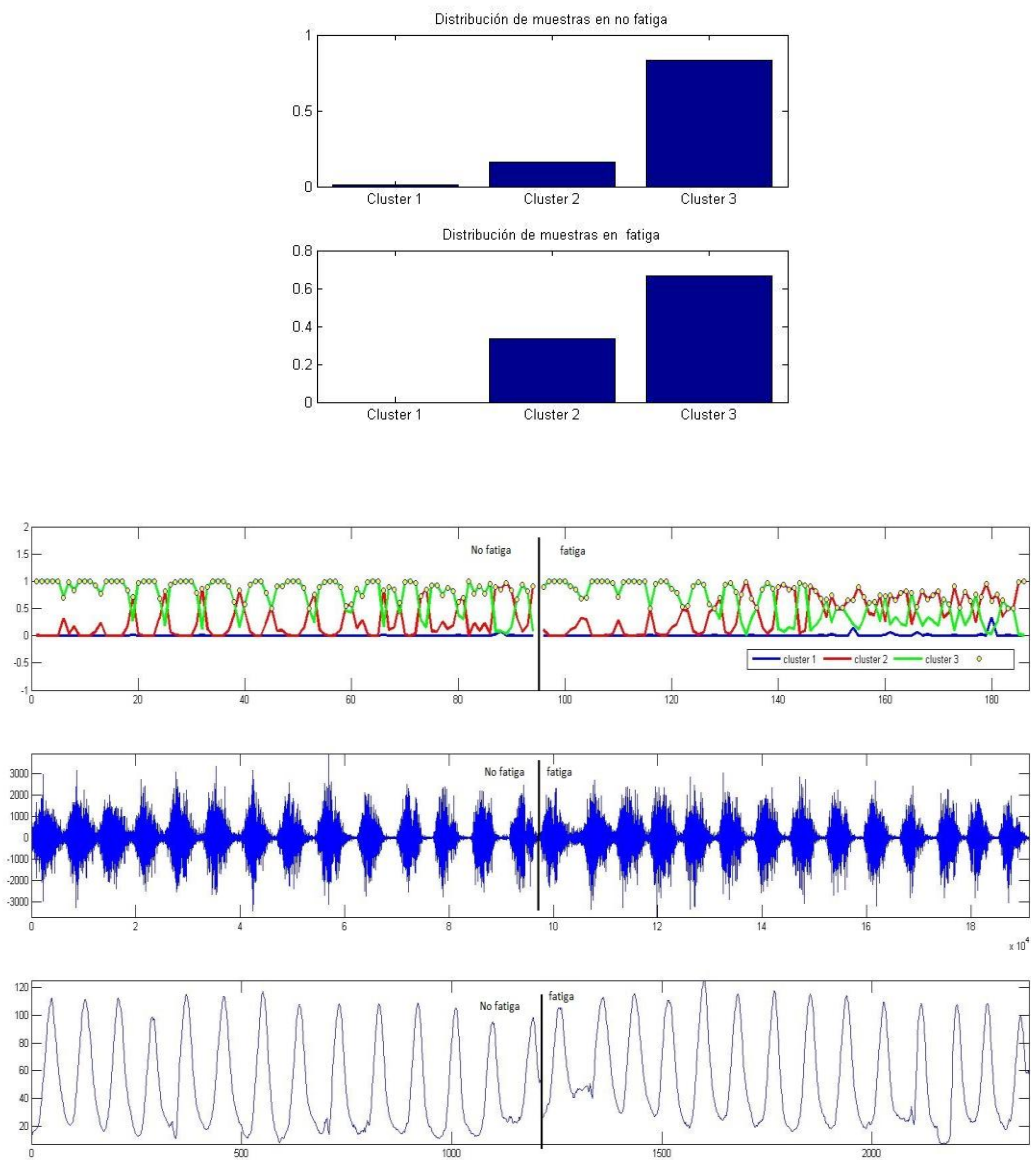


Figura 67. Resultados de clasificación para el Sujeto 6 en ejercicio de Hombro en no fatiga y fatiga.
De mayor a menor fatiga los clusters son el 1, el 2 y el 3. Azul, rojo y verde respectivamente.

Anexo IV

Cronograma y desarrollo de algoritmos

En este anexo se desglosará de forma general la repartición del trabajo realizado en la duración del proyecto, así como los programas generados en cada fase. La duración del proyecto ha abarcado desde Septiembre de 2013 a Junio de 2014 (ambos inclusive), la repartición del trabajo se puede observar en la tabla XXXXXX.

Se ha utilizado el algoritmo de EM diseñado por Mo Chen [31] para la parte de entrenamiento del algoritmo de detección de fatiga, los ficheros que incluye están marcados por un asterisco en la tabla.

El total de líneas de código desarrolladas asciende a 1413. A continuación se comenta la funcionalidad de cada fichero desarrollado así como las líneas de código que contiene:

1. Fmed_Numerically.m : Obtiene la frecuencia mediana a partir del espectro de frecuencias de la señal. 35 líneas de código
2. Zerocrossing.m: Obtiene los cruces por cero de una señal. 10 líneas de código.
3. DimitrovIndex.m: Calcula el índice espectral de dimitrov. 16 líneas de código.
4. ProcesaMCV: Obtiene la amplitud de referencia respecto de la que normalizar el EMG. 80 líneas de código.
5. AnálisisDinámica: Automatiza el proceso de cálculo de los indicadores de fatiga para cada sujeto y músculo. 80 líneas de código.
6. CargarDatos.m: Carga los datos (EMG, cinemática, etc.) desde fichero de un sujeto dado. 40 líneas de código.
7. Parámetros.m: Realiza el análisis de la señal dada, calculando MNF, Fmed, FI, RMS y ZC para cada ventana de análisis. 112 líneas de código.
8. EMG2Activation.m: Procesa el EMG para obtener el nivel de activación. 20 líneas de código.

9. SeleccionaryPartir.m: Permite partir una señal en trozos indicados por el usuario. 25 líneas de código.
10. ChangesVSPower.m: Muestra la distribución de los indicadores de fatiga para todos los sujetos respecto del Power output. 300 líneas de código.
11. plotearDatos.m: Muestra la evolución de los indicadores de fatiga en el tiempo. 70 líneas de código.
12. CrossValidation.m: Implementa el proceso de validación cruzada para seleccionar el número de sinergias. 38 líneas de código.
13. Nnmf.m: Implementa el algoritmo de *non negative matrix factorization*. 35 líneas de código.
14. VE.m: Calcula la varianza explicada para unos datos y su estimación. 10 líneas de código.
15. Sinergias.m: Obtiene las sinergias en fatiga y no fatiga para un sujeto. 33 líneas de código.
16. EntrenaMusculos.m: Entrena los 13 músculos utilizados en este trabajo, para hallar los niveles de fatiga de cada uno. 15 líneas de código.
17. Entrenar1Musculo.m: Entrena un músculo en concreto para obtener los diferentes niveles de fatiga. 45 líneas de código.
18. Clasi.m: Clasifica las muestras en fatiga y no fatiga de un sujeto en los diferentes niveles de fatiga. 36 líneas de código.
19. Prob_over_time.m: Obtiene la probabilidad de pertenencia a cada cluster para cada muestra. 15 líneas de código.
20. HillBasedModel.m: Implementa el modelo de Hill. Desarrollado por Diana Ruiz Bueno (directora de este trabajo), adaptado a los músculos modelados en este trabajo. 150 líneas de código.
21. generaMuestras.m: Genera las muestras que se utilizan en clasificación para un determinado sujeto. 20 líneas de código.
22. EMGfromRAW.m: Procesa todos los ficheros de medidas obtenidos durante la experimentación para que puedan ser tratados por el resto de algoritmos. 260 líneas de código.
23. GeneraMots.m: Genera los ficheros '.mot' que hacen de entrada a OpenSim para un determinado sujeto (cada fichero '.mot' es una repetición de un ejercicio). 50 líneas de código.

24. Muestras.m: Sincroniza el EMG y la cinemática medida para poder extraer medidas solo de las extensiones o de las flexiones del ejercicio. 60 líneas de código.
25. Procesa_Cinéticas.m: Procesa los ficheros de cinética devueltos por openSim para que puedan ser usados por el modelo de músculo. 28 líneas de código.

Periodo	Trabajo realizado	Código desarrollado
Septiembre y Octubre	Lectura y documentación. Estudio del estado del arte en detección de fatiga	-
Noviembre y Diciembre Y parte de Enero	Selección de indicadores de fatiga a utilizar, implementación de los mismos y primeros experimentos para comprobar su funcionamiento.	Fmed_Numerically.m Zerocrossing.m DimitrovIndex.m ProcesaMCV.m AnalisisDinamica.m CargarDatos.m Parametros.m EMG2Activation.m SeleccinaryPartir.m ChangesVsPower.m plotearDatos.m
Resto de Enero y parte de Febrero	Estudio y desarrollo de las sinergias	CrossValidation.m Nnmf.m VE.m Sinergias.m
Resto de Febrero y Marzo	Estudio y desarrollo del algoritmo de detección de fatiga y su implantación en el modelo de Hill.	Emgm.m* Spread.m* Logsumexp.m* EntrenaMusculos.m Entrenar1Musculo.m Clasi.m Prob_over_time.m HillBasedModel.m
Abril y Mayo	Experimentación final para obtener datos de entrenamiento y validación. Entrenamiento y validación del algoritmo. Obtención de resultados.	generaMuestras.m EMGfromRAW.m GeneraMots.m Muestras.m Procesa_Cinéticas.m
Junio	Redacción de la memoria	-

Anexo V

Funcionamiento de Kinect

Kinect es una cámara de profundidad diseñada por Microsoft en colaboración con PrimeSense y originalmente pensada como un periférico para la consola de videojuegos Xbox 360. Se basa en un emisor infrarrojos y una cámara Kinect, registra la distancia de los objetos que se encuentren en la escena creando una imagen de profundidad. Para ello se utiliza luz infrarroja que no capta el aspecto de los objetos si no su posición en la escena. Esta imagen de profundidad se muestra en blanco y negro con algo de distorsión. Las partes más claras son las más cercanas y las más oscuras son las más alejadas (figura 11).

El bajo precio y buen funcionamiento de Kinect ha hecho que se haya abierto a muchos más mercados que el de los videojuegos, utilizándose en gran variedad de aplicaciones en el campo de la visión por computador. Gran parte de este éxito se debe al desarrollo de controladores de código abierto para poder manejar Kinect. De hecho el programa desarrollado en este proyecto se basa en el software lanzado por PrimeSense, que permite manejar y procesar la imagen de Kinect de forma muy sencilla para detectar sujetos y localizar sus articulaciones en tres dimensiones, llamado OpenNI.



Figura 68. Imagen de profundidad de Kinect

Algoritmo de detección de sujetos y obtención de información cinemática

OpenNI ofrece funcionalidades para procesar las imágenes con el fin de detectar y rastrear a las personas. Una vez detectada una persona, OpenNI puede devolver la posición de cada articulación. Esto es exactamente lo que necesitamos pues a partir de la posición de cada articulación en cada instante podemos extraer las ángulos de las extremidades y su velocidad mediante unos simples cálculos.

El proceso completo que sigue el programa a la hora de detectar un nuevo sujeto y registrar su información cinemática es el siguiente:

1. **Detección del sujeto:** Comprende desde que el sujeto entra en el rango de visión de la Kinect hasta que esta lo detecta. La figura 12 ofrece una visión de esta fase.




Figura 69. Detección de un sujeto. Kinect da un color a cada sujeto que detecta

2. **Calibración:** Una vez detectado un sujeto, empieza una fase de calibración en la que el sujeto debe mantener una pose definida, llamada pose PSI (figura 14), consistente en permanecer con los pies juntos y los brazos levantados por encima de los hombros a ambos lados de la cabeza. Esto hace que OpenNI pueda medir la longitud de los brazos, el tamaño del torso y el ancho. OpenNI usará esta información para hacer el seguimiento de todas las articulaciones del esqueleto de forma rápida y precisa. Es en esta fase donde OpenNI superpondrá a la figura del sujeto el *skeleton* que utiliza para hacer el seguimiento de las articulaciones, este *skeleton* es una representación simplificada del esqueleto humano que contiene las distintas articulaciones medidas (Figura 13)




Figura 70. Fase de calibración




Figura 71. Esquema del *skeleton* usado por OpenNI

3. **Seguimiento:** Una vez detectado el sujeto y calibrado el *skeleton*, sólo queda realizar el seguimiento y registrar la posición y el ángulo de cada extremidad en cada instante. Para obtener el ángulo de una extremidad a partir de la posición de sus tres articulaciones se usa el algoritmo mostrado en el algoritmo 1 (en pseudocódigo).

```

function AnguloExtremidad( Vector articulacion1, Vector articulacion2,
                          Vector articulacion3)
{
  % Obtenemos vector entre articulación superior (hombro o cadera)
  % y central (codo o rodilla)
  Vector mitadSuperior = (articulacion1.x - articulacion2.x,
                          articulacion1.y - articulacion2.y,
                          articulacion1.z - articulacion2.z);

  % Obtenemos vector entre articulación central (codo o rodilla)
  % e inferior (muñeca o tobillo)
  Vector mitadInferior = (articulacion3.x - articulacion2.x,
                          articulacion3.y - articulacion2.y,
                          articulacion3.z - articulacion2.z);

  Float angulo = AnguloEntreVectores(mitadSuperior, mitadInferior);

  devolver angulo;
}

function AnguloEntreVectores(Vector v1, Vector v2)
{
  % Normalizamos ambos vectores
  v1 = normalizar(v1);
  v2 = normalizar(v2);

  % Calculamos producto escalar, y calculamos angulo
  float prodEscalar = v1.x*v2.x + v1.y*v2.y + v1.z*v2.z
  float angulo = acos(prodEscalar) * 180 / PI;
  devolver angulo
}

```

Algoritmo 1. Algoritmo para la obtención del ángulo de una extremidad. Se calcula a partir de la posición de sus tres articulaciones (Hombro, codo, muñeca, o cadera, rodilla, tobillo)

Anexo VI

Transformada Wavelet

Para explicar la transformada Wavelet es necesario empezar hablando de la transformada de Fourier, y seguir la evolución. La transformada de Fourier, definida por:

$$F(k) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} f(x) e^{-ikx} dx, \quad (6)$$

con k una variable real continua, presenta un buen rendimiento en el análisis de señales periódicas y razonablemente regulares, ya que utiliza la señal completa y analiza la energía de la distribución de frecuencias como un todo, pero sin poder hacer hincapié en los detalles que puedan ser relevantes, por lo que no resulta tan efectiva cuando se trata de señales irregulares, como la que se puede presentar cuando existen anomalías de funcionamiento. Proporciona resultados correctos acerca de las frecuencias de las ondas componentes de la señal y de su magnitud energética, pero no da información temporal acerca de las mismas, es decir, cuando se producen.

Para intentar corregir estas deficiencias se desarrolló **la transformada rápida STFT** (*Short Time Fourier Transform*), definida como:

$$S_f(\omega, \tau) = \int f(t) g^*(t - \tau) e^{-i\omega t} dt, \quad (7)$$

Donde $g(t)$ es una ventana deslizante, la cual tiene un ancho fijo y cambia a lo largo del eje x por un factor τ .

Básicamente consiste en dividir la señal en diferentes partes donde se puede asumir que la señal es estacionaria. La señal es multiplicada por la función ventana, cuya anchura debe ser igual a parte de la señal que se puede considerar como estacionaria. De este

modo, se revela la información en frecuencia localizada temporalmente en el dominio efectivo de la ventana. Desplazando a lo largo del eje x la ventana se cubre el dominio de la señal obteniéndose la completa información tiempo - frecuencia de la misma.

Sin embargo la STFT no soluciona todos los problemas de la transformada de Fourier, pues debido a la restricción de establecer una ventana de tamaño fijo no es capaz de obtener una relación exacta tiempo-frecuencia de la señal. Cuanto más pequeña es la ventana más resolución temporal conseguimos (el trozo de señal analizado es más pequeño) sin embargo peor resolución frecuencial obtenemos. En consecuencia existe un compromiso entre una buena resolución en tiempo o una buena resolución en frecuencia(figura 5)




Figura 72. Representación en tiempo-frecuencia. A la izquierda mejor resolución temporal y a la derecha mejor resolución frecuencial.

Aquí es donde aparece la transformada wavelet, que nos permite manejar diferentes resoluciones frecuenciales y temporales (Figura 6). Generalmente en las bajas frecuencias de una señal se encuentran la mayor parte de la información, representando las altas frecuencias el ruido, de ahí que no resulte atractivo ni eficiente analizar una señal con la misma resolución para todas las frecuencias.

Básicamente, lo que hace la transformada wavelet es filtrar una señal en el dominio del tiempo mediante filtros paso bajo y paso alto que eliminan ciertas componentes de alta o baja frecuencia de la señal, el procedimiento se repite para las señales resultantes del proceso de filtrado anterior.

La transformada continua wavelet(CWT) se define como:

$$W_f(s, \tau) = \int f(t) \Psi_{s,\tau}^*(t) dt \quad (8)$$

Las wavelets son generadas a partir de la traslación y cambio de escala de una misma función wavelet $\psi(t)$, llamada "wavelet madre", y se define como:

$$\psi_{s,\tau}(t) = \frac{1}{\sqrt{s}} \psi\left(\frac{t-\tau}{s}\right) \quad (9)$$

Donde s es el factor de escala y τ es el factor de traslación (figura 7).

Las wavelets $\psi_{s,\tau}(t)$ generadas de la misma función wavelet madre $\psi(t)$ tienen diferente escala s y ubicación τ , pero tienen todas la misma forma. Se utilizan siempre factores de escala $s > 0$. Las Wavelets son dilatadas cuando la escala $s > 1$, y son contraídas cuando $s < 1$. Así, cambiando el valor de s se cubren rangos diferentes de frecuencias. Valores grandes del parámetro s corresponden a frecuencias de menor rango, o una escala grande de $\psi_{s,\tau}(t)$. Valores pequeños de s corresponden a frecuencias de mayor rango o una escala muy pequeña de $\psi_{s,\tau}(t)$.

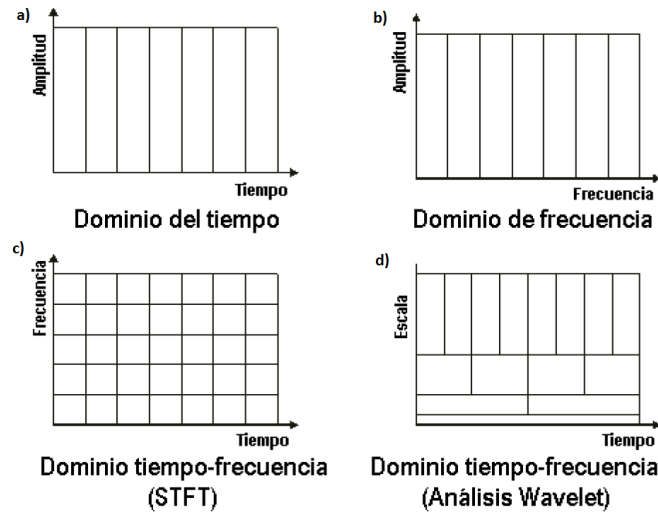


Figura 73. Diferentes técnicas de análisis y sus resoluciones tiempo-frecuenciales. a) Estudio tradicional en el dominio del tiempo. b) Estudio según la transformada de Fourier, la amplitud se mide en función de la frecuencia. c) Estudio según la STFT, ya se obtiene resolución tanto en tiempo como en frecuencia, sin embargo el intervalo de estudio se mantiene fijo. d) Estudio mediante wavelets, el intervalo entre frecuencias de estudio es función del punto del espectro en que nos encontremos. Aparece el concepto de escala relacionado con la frecuencia.




Figura 74. Dilatación y traslación de una wavelet madre.

GLOSARIO

α	Porcentaje de fibras rápidas del elemento contráctil
ANC	Anconeus
BIC long	Biceps long head
BICshort	Biceps short head
BRA	Brachialis
BRD	Brachioradialis
ECRL	Extensor carpi radialis longus
E_{rms}	error cuadrático medio
f_{ANC}	factor de escala de la activación de músculo ANC
f_{BIC}	factor de escala de la activación de músculo BIC long
f_{BRA}	factor de escala de la activación de músculo BRA
F_{CE}	fuerza del elemento contráctil
F_{CEmax}	fuerza máxima del elemento contráctil
FCR	Flexor Carpi Radialis
f_{geom}	factor geométrico del modelo
F_i	Fuerza muscular total del músculo i
f_l	relación entre fuerza muscular y longitud de músculo
F_{PE}	fuerza del elemento paralelo
F_{PEmax}	fuerza máxima del elemento paralelo
F_{SE}	fuerza del elemento en serie
F_{SEmax}	fuerza máxima del elemento en serie
f_v	relación entre fuerza muscular y velocidad de contracción
L_{CE0}	longitud de fibra óptima
ΔL_{CE}	variación de longitud del elemento contráctil con respecto al reposo
ΔL_{CEmax}	variación máxima de la longitud del elemento contráctil
L_m	longitud de músculo
\widetilde{L}_m	longitud de músculo-fibra normalizada
ΔL_{PE}	variación de longitud del elemento paralelo con respecto al reposo
ΔL_{PEmax}	variación máxima de la longitud del elemento paralelo
ΔL_{SE}	variación de longitud del elemento en serie con respecto al reposo
ΔL_{SEmax}	variación máxima de la longitud del elemento en serie

L_{TS}	longitud del tendón en reposo
M_{neto}	momento neto en la articulación
MVC	maxima contracción voluntaria
PT	Pronator teres
S_{PE}	factor de forma del elemento paralelo
S_{SE}	factor de forma del elemento contráctil
TRlat	Triceps lateral head
TRlong	Triceps long head
TRmed	Triceps medial head
U	activación muscular normalizada
V_{CE0}	máxima velocidad elemento contráctil con nivel de activación máximo
V_{CE}	velocidad de contracción del elemento contráctil
V_{CEmax}	velocidad máxima del elemento contráctil con